

Федеральное государственное автономное
образовательное учреждение
высшего образования
«СИБИРСКИЙ ФЕДЕРАЛЬНЫЙ УНИВЕРСИТЕТ»

институт

кафедра

УТВЕРЖДАЮ
Заведующий кафедрой
_____ Э.А. Петровский

« ____ » _____ 2016 г.

МАГИСТЕРСКАЯ ДИССЕРТАЦИЯ

Оптимизация моделей управления производственными системами нефте-
газового комплекса

15.04.02 Технологические машины и оборудование
15.04.02.02 Надежность технологических машин и оборудования
нефтегазового комплекса

Научный руководитель	_____	<u>к. т. н. доцент</u>	<u>В.В Бухтояров</u>
	подпись, дата	должность, ученая степень	инициалы, фамилия
Выпускник	_____		<u>А.И Ляхов</u>
	подпись, дата		инициалы, фамилия
Рецензент	_____	_____	_____
	подпись, дата	должность, ученая степень	инициалы, фамилия

Красноярск 2016

Федеральное государственное автономное
образовательное учреждение
высшего образования
«СИБИРСКИЙ ФЕДЕРАЛЬНЫЙ УНИВЕРСИТЕТ»

институт

кафедра

УТВЕРЖДАЮ
Заведующий кафедрой
_____ Э.А. Петровский

« ____ » _____ 2016 г.

ЗАДАНИЕ
НА ВЫПУСКНУЮ КВАЛИФИКАЦИОННУЮ РАБОТУ
в форме магистерской диссертации

Студенту Ляхов Антон Иванович

(фамилия, имя, отчество)

Группа НМ14-01М Направление 15.04.02.02

(код)

Надежность технологических машин и оборудования нефтегазового комплекса

(наименование)

Тема выпускной квалификационной работы «Оптимизация моделей управления производственными системами нефтегазового комплекса»

Утверждена приказом по университету № _____ от _____

Руководитель ВКР В.В. Бухтояров, доцент кафедры Технологические машины и оборудование нефтегазового комплекса, институт нефти и газа, Сибирский федеральный университет

(инициалы, фамилия, место работы и должность)

Исходные данные для ВКР:

Справочники по оборудованию и технологическим машинам нефтегазового комплекса, справочники и методические разработки по теории управления производственными системами, технологические расчёты установок переработки нефти, методики построения и оптимизации моделей управления технологическим оборудованием нефтегазового комплекса, научные статьи и диссертации по теме ВКР.

Перечень рассматриваемых вопросов (разделов ВКР) :

1. Моделирование и управление производственными системами НГК:

- Анализ проблемы управления процессами нефтепереработки

- Моделирование технологических установок производственных систем нефтепереработки;

- Общие сведения об адаптивных системах управления

- Задача автоматического управления процессами нефтепереработки по параметрам потоков

2. Методы построения и оптимизации моделей технологических систем нефтегазового комплекса.

- Методы построения моделей технологических систем нефтегазового комплекса

- Алгоритмы параметрической оптимизации моделей

- Эволюционный генетический алгоритм оптимизации параметров моделей технологических систем нефтегазового комплекса

3. Исследование эффективности методов построения и оптимизации моделей технологических систем.

Перечень графического или иллюстративного материала с указанием основных чертежей, плакатов: _____

Руководитель ВКР _____

подпись

В.В Бухтояров

инициалы и фамилия

Задание принял к исполнению _____

А.И Ляхов

подпись, инициалы и фамилия студента

« ____ » _____ 20__ г.

АННОТАЦИЯ

Предметом исследования данной магистерской диссертации является проблема оперативного управления процессами переработки нефти.

В диссертации рассматриваются следующие исследовательские вопросы:

- 1) Каковы взаимосвязи между входными и выходными параметрами технологических процессов?
- 2) Какие алгоритмы построения моделей технологических процессов, применимы к установкам нефтегазового комплекса?
- 3) Целесообразно ли применение определенных оптимизационных алгоритмов для повышения качества управления?
- 4) Применение каких оптимизационных алгоритмов приведет к определению эффективных значений управляющих параметров?

В диссертации рассмотрены возможности применения известных алгоритмов построения регрессионных моделей, в качестве основы для построения модели технологического процесса в нефтегазовом комплексе.

Определен наиболее эффективный метод оптимизации параметров моделей управления технологическими системами нефтегазового комплекса.

Проведено численное экспериментальное исследование, результаты которого подтвердили эффективность сформулированного в работе предложения по использованию эволюционного генетического алгоритма для параметрической оптимизации моделей технологических установок, эксплуатируемых в составе производственных систем нефтегазового комплекса.

Ключевые слова: Технологический процесс, алгоритм оптимизации, моделирование, регрессионная модель, численные исследования, эффективность управления, управляющие параметры.

СОДЕРЖАНИЕ

ВВЕДЕНИЕ	7
1 МОДЕЛИРОВАНИЕ И УПРАВЛЕНИЕ ПРОИЗВОДСТВЕННЫМИ СИСТЕМАМИ НГК	11
1.1 Анализ проблемы управления процессами нефтепереработки	11
1.2 Моделирование технологических установок производственных систем нефтепереработки	13
1.3 Общие сведения об адаптивных системах управления	17
1.4 Задача автоматического управления процессами нефтепереработки по параметрам продуктов	24
Выводы	26
2 МЕТОДЫ ПОСТРОЕНИЯ И ОПТИМИЗАЦИЯ МОДЕЛЕЙ ТЕХНОЛОГИЧЕСКИХ СИСТЕМ НЕФТЕГАЗОВОГО КОМПЛЕКСА	28
2.1 Методы построения моделей технологических систем нефтегазового комплекса	29
2.2 Алгоритмы параметрической оптимизации моделей	61
2.3 Эволюционный генетический алгоритм оптимизации параметров моделей технологических систем нефтегазового комплекса	66
Выводы	72
3 ИССЛЕДОВАНИЕ ЭФФЕКТИВНОСТИ МЕТОДОВ ПОСТРОЕНИЯ И ОПТИМИЗАЦИИ МОДЕЛЕЙ ТЕХНОЛОГИЧЕСКИХ СИСТЕМ	74
3.1 Исследование эффективности методов моделирования на тестовых задачах	76
3.2 Моделирование вакуумных установок	78
3.3 Результаты решения задачи моделирования технологической установки колонны к-5	82

3.4 Анализ результатов численных исследований методов моделирования и оптимизации моделей технологических систем _____	97
Выводы _____	99
ЗАКЛЮЧЕНИЕ _____	102
СПИСОК ИСПОЛЬЗОВАННЫХ ИСТОЧНИКОВ _____	105
ПРИЛОЖЕНИЕ А _____	111
ПРИЛОЖЕНИЕ Б _____	112

ВВЕДЕНИЕ

Одной из важнейших проблем, возникающих при исследовании различных объектов, процессов и систем, является построение моделей этих процессов и систем. Очевидно, различных объектов, с которыми приходится сталкиваться – бесчисленное множество, и одного универсального правила для построения моделей не существует. Существуют лишь некоторые обобщения и рекомендации по построению моделей. Выделены различные способы построения моделей того или иного типа объектов.

Один из способов построения моделей основан на применении непараметрических процедур для описания функционирования объекта, описания связи входных, выходных переменных объекта. Зачастую мы имеем не просто объект, а несколько объектов, объединенных в одну систему, и функционирующих как единое целое. При этом выход одного элемента системы может являться входом другого элемента системы, появляется множество промежуточных связей. Если некоторые соотношения, описывающие функционирование объекта известны точно (например, заданы известным уравнением), то применение лишь непараметрических процедур для описания объекта становится не совсем оправданным. Очевидным становится выбор в пользу сочетания в одной модели известных заранее соотношений и соотношений восстановленных с помощью непараметрических процедур.

Построенные таким образом модели называют комбинированными. Применение комбинированных моделей позволяет системному аналитику более адекватные модели, учитывать известные соотношения (например, законы физики и др.), и в тоже время, применяя непараметрические процедуры, осваивать синтез моделей, построение которых было невозможно в виду не возможности установления точной связи между, например, входами выходами объекта.

При построении моделей зачастую сталкиваются с проблемой, известной как «проклятие размерности» - при увеличении размерности про-

странства переменных резко увеличивается объем выборки наблюдений, необходимый для построения адекватной модели. В реальных задачах объем выборки наблюдений зачастую ограничен невозможностью многократного проведения экспериментов, их дороговизной и др.

Построение модели объекта или процесса во многих случаях является одним из этапов создания адаптивной системы управления этими объектами или процессами. В рамках единой теории непараметрических систем развит подход синтеза непараметрических адаптивных алгоритмов управления. Применение таких алгоритмов совместно с методами моделирования систем позволяет создать комплексный подход, который отличается высокой степенью адаптивности и возможностью работать в условиях как отсутствия какой-либо информации структуре и параметрах рассматриваемых объектов или систем, так и в условиях, соответствующих уровню информации, достаточного для построения комбинированных моделей. В этой связи значительный интерес представляет разработка методов, позволяющих повысить эффективность алгоритмов управления такими системами, объектами или процессами.

Управление процессами подготовки и переработки нефти как правило производится в соответствии с технологическим регламентом, в котором оговариваются условия для режимных параметров ведения процесса и нормируются показатели качества получаемых продуктов.

Главной особенностью нефтеперерабатывающих производств является нестабильность характеристик сырья, определяющая необходимость изменения режимных параметров с целью поддержания нормируемых показателей качества получаемых продуктов. Так, например, состав сырья, поступающего на установки комплексной подготовки нефти (УКПН) может изменяться за сутки пять-десять раз. При этом изменяются фракционный и химический составы, содержание воды и солей. Сырье для нефтеперерабатывающих заводов нормируется по целому ряду параметров: содержанию воды и солей, количеству летучих углеводородов, но тем не менее химический и фракционный со-

ставы нефтей также могут изменяться существенным образом. В последние несколько лет НПЗ широко практикуется использование так называемого «давальческого» сырья и переработка сырья «с колес». Это сырье является очень часто смесью нескольких нефтей, полученных с различных месторождений и обладающих весьма различными свойствами и характеристиками.

Известно, что несмотря на огромное количество работ по изучению свойств нефтей отдельных месторождений, многие вопросы управления технологией переработки этих нефтей остаются открытыми. Необходимость использования смесей нефтей усугубляет эти проблемы, в частности, не позволяет оперативно анализировать состав сырья и вырабатывать рекомендации по ведению технологических режимов процессов переработки нефти. Острота проблемы несколько снижается для процессов вторичной переработки и нефтехимического синтеза, где в качестве сырья используются продукты первичной переработки нефти, качество которых поддерживается в определенных пределах. Тем не менее, влияние нестабильности характеристик сырья процессов первичной переработки нефти отражается на режиме и качестве продуктов вторичной переработки нефти и нефтехимического синтеза. Это является одной из причин также обуславливающих необходимость повышения качества управления процессами первичной переработки нефти.

В условиях рыночной экономики выпуск продукции обусловлен потребительским спросом. Так, например, при производстве масел возникает необходимость в производстве небольших партий различных по назначению и свойствам масел, потребное количество которых производится за двое-трое суток. Перенастройка технологического режима установок атмосферно-вакуумных трубчаток (АВТ) часто занимает время от нескольких часов до двух суток даже в условиях стабильного по качеству сырья.

Сочетание нестабильного по характеристикам сырья и изменяющихся требований к показателям качества получаемых продуктов являются основными факторами, которые делают задачу подбора технологического режима

чрезвычайно сложной. Трудности выбора режимных параметров связаны со следующими причинами.

Во-первых, отсутствуют (или крайне ограничены) средства метрологического контроля качества продуктов подготовки и переработки нефти на потоке, в связи с чем управление производится на основе информации, получаемой путем отбора проб и проведения лабораторных анализов. Стоимость и технические возможности лабораторного контроля на предприятиях позволяют делать не более двух-трех анализов в сутки. Заметим, что частота проведения анализов на УКПН, как правило, еще меньше: обычно один-два анализа за сутки.

Во-вторых, качество процессов управления с учетом задержек, инерционности производственных процессов, достигающих в процессах подготовки нефти время от нескольких часов до нескольких десятков часов, а в процессах нефтепереработки от нескольких минут до десятков минут, принципиально не может быть сделано высоким, т.к. низкое быстродействие автоматических систем регулирования не позволяет подавлять возмущения относительно более высокой частоты.

В-третьих, объем информации, который предлагается оператору (или автоматическому устройству) для выработки управляющих воздействий достаточно велик. Часто информация имеет нечеткий характер, а оценка качества того или иного решения на управление проводится по многим плохо формализованным критериям. Это приводит к тому, что решения на управление формируются обычно экспертным образом, и качество управления зависит от опыта и других личных качеств обслуживающего персонала.

Сказанное позволяет заключить, что проблема оперативного управления процессами переработки нефти является весьма актуальной, а ее разрешение позволяет заметно повысить эффективность производства.

1 МОДЕЛИРОВАНИЕ И УПРАВЛЕНИЕ ПРОИЗВОДСТВЕННЫМИ СИСТЕМАМИ НГК

1.1 Анализ проблемы управления процессами нефтепереработки

Одной из основных особенностей многих технологических процессов нефтепереработки является большая зависимость показателей эффективности от характеристик товарных продуктов или полуфабрикатов производства.

В связи с быстро изменяющимися требованиями рынка нефтепродуктов и в условиях больших колебаний качества сырья оперативное управление процессами нефтепереработки с целью поддержания оптимальных или, в частном случае, заданных характеристик нефтепродуктов становится необходимым. Решение задачи автоматического регулирования параметров продуктов, т.е. их поддержание в заданных пределах, является основой для решения задачи оптимального управления и эффективности производства.

Показатели эффективности системы управления могут быть разбиты на четыре группы частных показателей эффективности:

1. Техничко-экономические показатели производства в целом (себестоимость, фондоотдача и т.д.);
2. Технические показатели работы технологических установок; эту группу составляет, в основном, показатели качества нефтепродуктов;
3. Показатели качества сепаратных (локальных) автоматических систем регулирования технологических параметров и динамических процессов объекта управления в целом;
4. Показатели, оценивающие надежность свойства системы управления, в том числе такие как безопасность, отказоустойчивость, живучесть и т.д.

Последняя группа показателей зависит от всего комплекса решений по управлению, технических и программных средств автоматизации, квалификации обслуживающего персонала, состояния технологического оборудования и относится поэтому к группе системных показателей.

С учетом размерности, наличия многочисленных и разнообразных ограничений решение задачи управления, можно обеспечить только на основе декомпозиции задачи, дискретизации состояний и подзадач, с обязательной координацией решений подзадач для выполнения системных ограничений [1-3].

Технические показатели являются базой для определения значений технико-экономических показателей работы технологических объектов, расчет которых в реальном масштабе времени может проводиться, как правило, только для стационарного состояния. Это означает, что накладываются ограничения на длительность переходных процессов при переходах из одного состояния в другое: время переходного процесса должно быть существенно меньше времени нахождения в стационарном состоянии. В противном случае возникает необходимость решения задачи оптимального управления дестабилизационными процессами [4]. Вторым путем снижения времени решения задачи управления является использование априорной и апостериорной информации методами, которые применяются в системах искусственного интеллекта [5,6].

В настоящее время имеется ряд программных продуктов, в которых решаются задачи планирования, оптимизации и выпуска продукции при условии, что априори известны технологические возможности установок, составы и свойства сырьевых, товарных (и полуфабрикатных) потоков, энергетические и экономические показатели эффективности и т.д. В частности, это пакет PIMS (Process Industry Modeling System), Bechtel Corporation, система ROM™ фирмы Simulation Sciences, USA, PRO II и ряд других.

Основные возможности данных пакетов состоят в том, что в режимах «offline» или «on line» моделируются и оптимизируются как распределение потоков по установкам производства в целом, так и режимы отдельных технологических процессов. Основным недостатком этих пакетов, в том числе рассчитанных на работу в режиме «on line», является необходимость обеспечения их большими объемами оперативной информации и работа со статиче-

скими состояниями технологического процесса. Кроме того, для реализации пакетов требуется мощная вычислительная техника, адаптация моделей представляет собой достаточно сложную и дорогостоящую процедуру. Тем не менее, можно считать, что решение задачи оптимального управления принципиально возможно, если обеспечивается возможность регулирования процессов по параметрам. Наибольшие проблемы, которые носят принципиальный характер, возникают при реализации планов на технологических установках в реальном масштабе времени. К ним относятся:

- отсутствие оперативной информации о сырье;
- отсутствие явной и однозначной связи между технологическими параметрами и показателями качества товарной продукции; из этого вытекает, что выбор управляющих воздействий неоднозначен;
- наличие динамики процессов из-за действия различных возмущений, часть из которых не измеряема. Следствием – этого является проблема обеспечения качества динамических процессов управления.

1.2 Моделирование технологических установок производственных систем нефтепереработки

Основными параметрами (ОП), по которым проводится управление в нефтепереработке и нефтехимии, являются:

1. Температуры кипения t^α при заданной величине отгона α , в том числе:

t^α – значение температуры начала кипения;

t^5 – значение температуры выкипания 5% и другие характерные точки истинных температур кипения (ИТК) [7-9].

2. Вязкость, оцениваемая либо динамическим μ , либо кинематическим ν коэффициентами вязкости.

3. Плотность ρ .

4. Температура вспышки $t^{\text{всп}}$.

5. Давление насыщенных паров $p^{\text{нас}}$.
6. Цвет.
7. Температура застывания $t^{\text{зс}}$.
8. Температура кристаллизации $t^{\text{кр}}$.
9. Состав, концентрация, pH и т.д.

Существуют два основных подхода к получению информации об ОП. Первый, который можно назвать «измерительным», состоит в использовании соответствующих анализаторов; второй («модельный») базируется на использовании моделей, у которых в качестве входных координат используются косвенные параметры [10]. Некоторые типичные характеристики анализаторов приведены в приложении А.

Анализ возможностей использования приборов и приборных комплексов для управления технологическими процессами позволяет заключить:

- 1) точность измерения, обеспечиваемая приборами, как правило в несколько раз ниже требуемой (исключение составляют вискозиметры и плотномеры);
- 2) динамические возможности характеризуются постоянными времени порядка 10...60 мин., что неприемлемо для качественного оперативного управления;
- 3) надежность показатели низкие и не соответствуют требованиям к техническим средствам управления [11];
- 4) для обслуживания приборов требуется высококвалифицированный персонал и средства поверки и обеспечения сходимости измерений (стандартные образцы). По литературным данным попытки обойти указанные недостатки делаются в следующих направлениях.

В ряде работ для анализа фракционного состава, например, с целью повышения оперативности и упрощения измерений предлагается использовать разгонку по методике ASTM- Д86 с дальнейшим пересчетом ее в кривую ИТК [12]. Однако, основные недостатки «измерительного» подхода имеют место и в этом случае. Коррекцию измерений с учетом динамических харак-

теристик вискозиметров предлагается проводить, например, в [13]. Это позволяет повысить точность, но остальные недостатки сохраняются, а надежные показатели даже ухудшаются. Заметим, что целый ряд показателей качества вообще не обеспечен измерительными приборами. Наконец, «измерительный» подход имеет еще один принципиальный недостаток: измерение ОП производится для уже полученных продуктов. С учетом динамических характеристик объектов, постоянные времени которых составляют часто десятки минут, стандартные методы регулирования не обеспечивают приемлемого качества процессов регулирования [14].

В связи с изложенным более перспективным является подход к получению ОП на основе моделей. Работы [15-17] в этом направлении подтверждает сделанный вывод.

Вычисление ПК для целей оперативного управления зачастую является единственно возможным вариантом их получения.

Модели для этих целей должны:

- 1) давать возможность проведения расчетов за время, в течение которого параметры технологических установок изменяются незначительно; обычно это время порядка нескольких секунд или десятков секунд;
- 2) быть достаточно простыми с тем, чтобы могли быть реализованы на серийных средствах;
- 3) содержать механизмы адаптации к характеристикам конкретного объекта, сырья, технологического режима;
- 4) в качестве входных координат использовать технологические параметры и другую информацию, которая может быть получена оперативно измерениями на основе стандартных технических средств;
- 5) учитывать различие в динамических характеристиках каналов передачи воздействий объекта.

Два последних требования налагают весьма сильные ограничения на класс возможных математических моделей. В частности, требование измеримости (наблюдаемости) входных координат не позволяет использовать суще-

ствующие модели ректификации [18], экстракции [19], других нефтехимических процессов [20] даже при рассмотрении статических режимов с известным составом сырья. Это объясняется тем, что константы фазового равновесия, коэффициенты активности и ряд других параметров подбираются в этих моделях либо итеративно, либо эмпирически. Кроме того, использование подобных моделей приводит к необходимости решения неаналитических задач с краевыми условиями. Если же рассматривать те же задачи с учетом динамики объекта, то подобных моделей для многих процессов нет, за исключением некоторых частных случаев [21].

В связи с этим предлагается в качестве класса моделей для целей оперативного управления по ОП использовать статические модели, получаемые на основе отображений F с динамическими корректирующими звеньями в измерительных каналах и каналах передачи воздействий:

$$F: (T, R) \rightarrow \Gamma \quad (1.1)$$

где T - множество измеряемых технологических параметров и показателей качества, элементы которого рассматриваются как входные координаты;

Γ - множество моделируемых ПК продуктов производства;

R - множество параметров, задающих количественные и качественные характеристики входных для данного объекта потоков.

Выделение параметров входных потоков в отдельное множество R связано с тем, что оно играет для объекта роль внешней среды, в то время, как множество T с определенными оговорками можно рассматривать как множество, отражающее внутренние характеристики (свойства) технологического объекта.

Получение моделей на основе отображения F встречает две основные трудности. Первая связана с тем, что даже в условиях известного (заданного) состава сырья оператор отображения F как правило неизвестен. Более того, он может в общем случае либо отсутствовать, либо быть неоднозначным.

Вторая трудность определяется размерностью моделей и объемом необходимой для их построения информации. Общие методы построения формальных моделей [22] достаточно хорошо разработаны и базируются на корреляционном и регрессионном.

1.3 Общие сведения об адаптивных системах управления

Система управления называется адаптивной, если в ней текущая информация, помимо выработки управляющего воздействия, используется для изменения алгоритма управления. В неадаптивных системах управления текущая информация используется только для формирования управляющего воздействия.

Адаптивные системы управления применяются в тех случаях, когда поставленные задачи не удается выполнить с помощью обычных неадаптивных систем. К таким ситуациям можно отнести следующие ситуации:

- Начальной (априорной) информации об объекте недостаточно для построения системы управления (неадаптивной), позволяющей достичь поставленной цели.
- В процессе функционирования объекта управления его характеристики изменяются непредвиденным образом в широком диапазоне, что не позволяет применять системы управления с неадаптивными алгоритмами.

В последнее время в связи с большими возможностями современных вычислительных устройств и их сравнительной дешевизне методы адаптивного управления нашли практическое применение практически во всех областях технической деятельности, среди них особо можно выделить такие отрасли как робототехника, управление самолетами и ракетами, энергетические системы, управление сложными технологическими процессами.

Так, например, во время полета отдельные параметры, определяющие динамические свойства самолета, могут изменяться в десятки раз. В этих условиях с задачей качественного управления самолетом обычные неадаптивные системы управления могут не справиться.

Что касается технологических процессов, например в таких отраслях, как металлургия, нефтехимия, то в большинстве случаев они являются сложными, а их параметры и структура зачастую неизвестны из-за недостаточной априорной информации. Поэтому обычные системы управления во многих случаях не могут обеспечить качественного, а иногда и просто устойчивого управления такими технологическими процессами.

При разработке унифицированных регуляторов для широкого класса объектов параметры регуляторов заранее не могут быть точно рассчитаны и установлены. Поэтому если эти регуляторы являются неадаптивными, то при их использовании в каждом конкретном случае они требуют настройки. Использование адаптивных регуляторов избавляет экспертов от необходимости выполнения данной процедуры, что позволяет экономить временные, человеческие и, в конечном счете, что немаловажно, денежные ресурсы.

В большинстве случаев адаптивное управление преследует цель нейтрализации параметрической неопределенности или неизбежных изменений параметров объекта. Однако в некоторых случаях, в особенности при управлении технологическими процессами, где могут присутствовать сотни управляющих контуров, адаптивное управление также используется, чтобы уменьшить число конструктивных параметров ручной настройки и тем самым увеличить эффективность и практичность системы управления.

В целом можно выделить следующие задачи, которые позволяет решить использование адаптивных систем управления:

- Обеспечение оптимального режима работы систем управления в условиях неполной информации.
- Обеспечение работоспособности системы управления в условиях изменения параметров объекта в широких пределах.
- Создание унифицированных регуляторов для широкого класса объектов.

- Снижение технологических требований к изготовлению отдельных узлов и элементов.

- Сокращение сроков разработки и наладки систем.

1.3.1 Классификация адаптивных систем управления

1. По характеру изменений в управляющем устройстве различают два вида адаптивных систем:

- Самонастраивающиеся адаптивные системы – это системы, в которых изменяются только параметры алгоритма управления, а его структура остается неизменной.

- Самоорганизующиеся адаптивные системы- системы с изменяющейся структурой алгоритма управления.

2. По способу изучения объекта адаптивные системы разделяют на два типа:

- Поисковые. Адаптивная система управления называется поисковой, если в нее для изучения объекта подаются специальные (поисковые) сигналы. Среди поисковых систем широко распространены экстремальные системы. Целью управления в таких системах является поддержание системы в точке экстремума статических характеристик объекта. В таких системах для определения управляющих воздействий, обеспечивающих движение к экстремуму, к управляющему сигналу добавляется поисковый сигнал.

- Беспoisковые. В отличие от поисковых систем в беспoisковые системы никакие поисковые сигналы для изучения объекта не подаются.

3. Беспoisковые адаптивные системы управления по способу получения информации для подстройки параметров регулятора разделяют на следующие типы:

- Системы с эталонной моделью. Системы с эталонной моделью содержат динамическую модель системы, обладающую требуемым качеством.

- Системы с идентификатором, в литературе иногда называют, как системы с настраиваемой моделью.

1.3.2 Активное и пассивное накопление информации

По способам тестирования исследуемого объекта методы идентификации делятся на методы с активным накоплением информации и методы с пассивным накоплением информации.

Применение методов адаптации с активным накоплением информации предполагает подачу на вход объекта специально сформированных воздействий – детерминированных или случайного характера. Среди «традиционных» активных методов идентификации широкое распространение получили частотные методы, основанные на измерении установившихся входных сигналов исследуемого объекта, вызванных гармоническим входным воздействием. Для идентификации объектов используют и другие периодические воздействия – прямоугольные, треугольные, а также апериодические воздействия в виде ступенчатых, импульсных и других сигналов. В качестве случайных тестовых сигналов применяют, например, псевдослучайные двоичные последовательности.

Достоинство методов адаптации с активным накоплением информации заключается в нежесткости требования к априорным данным об объекте. Основываясь на методах планирования эксперимента, такую идентификацию можно осуществлять целенаправленно, что позволяет ускорять выявление закономерностей в зависимостях между переменными объекта и сокращать тем самым временные и материальные затраты на его испытания.

При использовании методов адаптации с пассивным накоплением информации объект находится в условиях нормального функционирования. При этом параметры его модели ищутся по результатам статистической обработки наблюдений естественных изменений величин на его входе и выходе. При использовании методов адаптации с пассивным накоплением информации применяют статистические принципы обработки данных измерений (например, методы корреляционного и регрессионного анализов, стохастиче-

ской аппроксимации). Преимуществом использования методов адаптации с пассивным накоплением информации является то, что для их применения достаточно регистрации переменных только в режимах рабочего функционирования объекта. Это особенно важно при идентификации реальных промышленных процессов с непрерывным производством дорогостоящего продукта. С другой стороны, такие методы сопряжены со значительными затратами времени на накопление и обработку информации. Кроме того, их применение возможно лишь в том случае, если воздействие на входе объекта обладает достаточно широким частотным спектром, который, по крайней мере, не меньше, чем полоса частот, в пределах которой необходимо оценить характеристики объекта.

1.3.3 Возможные схемы построения систем идентификации

При синтезе непараметрических алгоритмов важным является выбор схемы, соответствующей наличию или отсутствию сравнения получаемой модели с объектом. Различают две схемы: разомкнутую и замкнутую. Рассмотрим подробно принципы синтеза непараметрических алгоритмов при использовании этих схем.

Пусть $\vec{q}(t) \in R^n$ и $\vec{u}(t) \in R^k$ – векторы наблюдаемых случайных последовательностей, представляющие собой соответственно выходную и входную характеристики исследуемого объекта или процесса. Определим функцию решений $\hat{r} \in L^2$, представляющую собой выход (решение) адаптивной системы, а функцию отклика $w \in L^2$ будем рассматривать как реакцию исследуемого объекта на \hat{r} . Функция w поступает на вход адаптивной системы.

Ниже представлены блок-схема объекта и разомкнутой адаптивной системы и блок-схема объекта и замкнутой адаптивной системы.

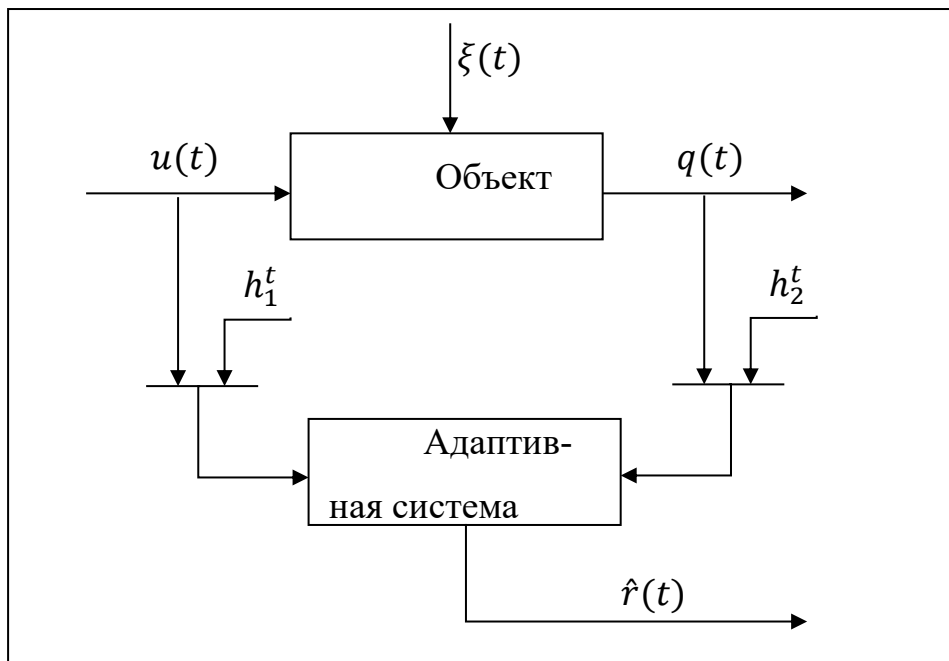


Рисунок 1.1 – Замкнутая адаптивная система

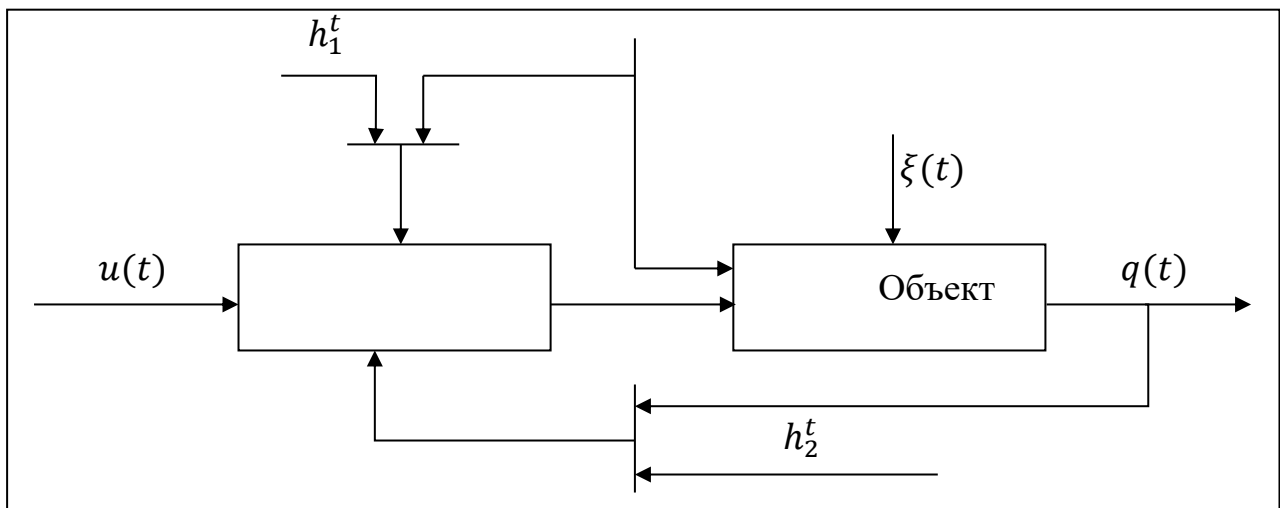


Рисунок 1.2 – Адаптивная система с замкнутой схемой

В введенных выше обозначения, для разомкнутой системы, представленной на рисунке, $\hat{r} = \hat{q}$, $w = u$, а для замкнутой системы $\hat{r} = u$, $w = \hat{q}$.

Если выбрать критерий оптимальности в виде:

$$R(\hat{r}) = M_w \{ M_r \{ Q(r, \hat{r}) / w \} \}, \quad (1.1)$$

где $Q(\cdot)$ – некоторая выпуклая функция, то задача отыскания наилучшего \hat{r} сводится к минимизации $R(\hat{r})$ по \hat{r} . Ясно, что вид \hat{r} будет определяться видом функции $Q(r, \hat{r})$. Если $Q(r, \hat{r}) = (r - \hat{r})^2$, то

$$\hat{r}(w) = M\{r/w\}. \quad (1.2)$$

В дальнейшем вопрос синтеза непараметрического алгоритма адаптации состоит в оценивании $\hat{r}(w)$ по наблюдениям $\vec{r}(s), \vec{w}(s)$, которые формируются из исходных выборок $\vec{q}(t), \vec{u}(t)$. Следует иметь в виду, что тип системы (замкнутая или разомкнутая) существенно влияет на оценивание $\hat{r}(w)$, но не влияет на вид $\hat{r}(w)$.

Важное значение для оценивания $\hat{r}(w)$ имеет характер поступления информации в адаптивную систему. Как уже упоминалось выше, накопление информации может носить пассивный или активный характер. Добавим, что может быть рассмотрен случай комбинированного накопления информации адаптивной системой. Кратко охарактеризуем упомянутые типы накопления информации в связи с задачей синтеза непараметрических алгоритмов адаптации.

Пассивный характер накопления информации. При пассивном характере накопления информации в адаптивной системе обучающая выборка $(r(i), w(i), i = \overline{1, s})$ сразу поступает в адаптивную систему. Задача сводится к оцениванию тем или иным образом оптимального решающего правила $\hat{r}^{\text{опт}}(w)$.

Активный характер накопления информации. При активном накоплении информации в адаптивной системе (что соответствует описанной выше замкнутой схеме адаптивной системы) в адаптивную систему последовательно подаются пары наблюдений: сначала $(r(1), w(1))$, затем $r(2), w(2)$ и т.д. Адаптивная система в этом случае существенно влияет на процесс обучения в отличие от систем с пассивным накоплением информации. Здесь важная

роль отводится решению вопроса о выработке адаптивной системой воздействий, которые подаются на объект, поскольку система замкнутая. Следовательно, в такой системе время обучения (адаптации) может существенно различаться в зависимости от характера выработки этих воздействий. Таким образом, при замкнутой схеме, обучение носит активный, дуальный характер.

В случае *комбинированного обучения* обучающая выборка $(r(i), w(i), i = \overline{1, s})$ вводится в адаптивную систему. А затем пополняется наблюдениями $(r(s + 1), w(s + 1)), r(s + 2), w(s + 2), \dots$ в этом случае обучение носит также активный характер и зависит от выработки адаптивной системой воздействий, которые подаются на объект.

Во всех схемах обучения задача в конечном счете сводится к статистическому оцениванию оптимального решающего правила $\hat{r}^{\text{опт}}(w)$. Темп (время оценивания) существенно зависит от характера обучения (активного или пассивного) и последнее приобретает принципиально важное значение при обучении адаптивных систем. Далее рассмотрим подробнее непараметрические алгоритмы адаптации при активном накоплении информации.

1.4 Задача автоматического управления процессами нефтепереработки по параметрам продуктов

Задача автоматического управления объектами нефтепереработки и нефтехимии имеет следующие особенности:

1. Формирование управляющих воздействий должно осуществляться в реальном масштабе времени.
2. Число регламентируемых параметров в общем случае не совпадает с числом управляющих воздействий; выбор управляющего воздействия недетерминирован.
3. Оценка качества управления производится по векторному критерию, элементы которого могут быть разбиты на несколько групп частных критериев, приоритеты между которыми, а также и внутри каждой групп, вообще говоря, могут быть не заданы или не формализованы.

4. Ресурсы управления ограничены как по числу управлений, так и по диапазону изменения управляющих воздействий.

5. Часть показателей качества могут быть противоречивыми в смысле реакции на управляющие воздействия.

6. Между каналами передачи управляющих и возмущающих воздействий в объекте существуют перекрестные динамические связи.

7. Информация об ограничениях, целях управления параметрах и структуре моделей объекта может носить случайный и (или) нечеткий характер.

Основными процессами в технологии нефтепереработки являются процессы разделения нефтяных смесей на ректификационных установках и экстракционных колоннах [23]. Типовая установка АВТ (атмосферно-вакуумная трубчатка) для разделения нефти на фракции содержит в своем составе колонну стабилизации для отгона фракций до $C_4 - C_4$, атмосферную часть - для выделения светлых нефтепродуктов (бензины, керосины, дизельное топливо) и вакуумную часть для выделения вакуумных дистиллятов или масляных фракций. Для светлых нефтепродуктов нормируемыми являются показатели фракционного состава фракций; температура начала и конца кипения ($t^{нк}$, $t^{кк}$), температуры выкипания 50% (t^{50}), иногда других характерных точек кривой истинных температур кипения (ИТК): t^5 , t^{10} , t^{90} , t^{95} , где индекс означает долю отгона α , %.

Для вакуумных колонн нормируемыми показателями продуктов разделения нефтяных смесей являются температура вспышки $t^{всп}$, коэффициент кинематической вязкости ν , цвет. Последний показатель косвенно характеризует количество тяжелых фракций в дистиллятах. Показатели качества продуктов разделения на вакуумной части зависят в основном от фракционного состава и, кроме того, в меньшей степени от химического состава фракций. Продукты разделения вакуумной части (масла и гудрон) прохо-

дят дальнейшую переработку на установках очистки масел и деасфальтизации соответственно.

В первом случае процесс часто ведется на основе использования свойств фенола, который способен экстрагировать тяжелые фракции. Во втором случае экстракция легких из гудрона обычно производится пропаном. Нормируемыми являются показатели, характеризующие содержание легких фракций в рафинатных продуктах и в остатке и показатели вязкости [23]. Значения этих показателей определяются двумя основными факторами: фракционным и химическим составами, которые достаточно сложным образом зависят от фракционного и химического состава сырья, а также состава экстрагента и параметров технологического режима. Существенным обстоятельством является то, что АВТ является узловым этапом нефтепереработки и от качества управления атмосферной и особенно вакуумной частями зависят показатели качества товарной продукции и экономичность производства в целом.

Рассмотрим вопросы моделирования атмосферной и вакуумной частей установки АВТм, для целей оперативного управления установкой по ПК продуктов разделения нефтяных смесей.

Выводы

В первой главе рассмотрена проблема управления технологическими установками в составе производственных систем нефтегазового комплекса. На примере установок нефтепереработки – вакуумных колонных установок, сформулирована проблема построения «быстрых» регрессионных моделей, позволяющих рассчитывать модельные значения и формировать или подбирать значения входных параметров таких установок в режиме, близком или соответствующем режиму реального времени без использования высокопроизводительных ЭВМ, что нецелесообразно и трудноосуществимо в условиях реального производства.

Описаны параметры рассматриваемых технологических установок, определена совокупность входных и выходных параметров соответствующих технологических процессов, моделирование которых позволит оценить режимы функционирования и состояния таких аппаратов, выработать оптимальное управление с учетом сформированной статической характеристики, описывающей зависимость выходных параметров от входных. Очевидно, что рациональный и эффективный выбор параметров и режимов функционирования отдельных технологических установок позволит в целом повысить эффективность производственных систем, в состав которых они входят и, как следствие, рационально распределять и использовать ресурсы производств нефтегазового комплекса в целом и предприятий нефтегазопереработки в частности.

2 МЕТОДЫ ПОСТРОЕНИЯ И ОПТИМИЗАЦИЯ МОДЕЛЕЙ ТЕХНОЛОГИЧЕСКИХ СИСТЕМ НЕФТЕГАЗОВОГО КОМПЛЕКСА

В качестве «быстрых» статических моделей очевидно могут быть использованы формальные, в частности, регрессионные соотношения. При этом требуется разрешить ряд вопросов:

- 1) определить структуру модели, т.е. входные координаты, вид уравнения регрессии и метод ее идентификации;
- 2) определить параметры модели, т.е. метод получения параметров, источник и объем исходной информации, критерий адекватности регрессионной модели;
- 3) оценить чувствительность решения к неучтенным параметрам и погрешностям измерения (или задания) входных и выходных координат объекта в исходной информации.

Существует значительное число методов построения и регрессионных моделей технологических объектов. В рамках данной диссертации рассматривается и анализируется эффективность следующих методов построения регрессионных моделей:

- 1) искусственные нейронные сети;
- 2) многомерные адаптивные регрессионные сплайны;
- 3) регрессионные деревья
- 4) непараметрические регрессионные модели.

В качестве базового метода для оценки эффективности моделей построенных перечисленными выше методами рассматривался метод линейной регрессии].

Выбор данных методов в качестве базовых для построений моделей технологических объектов обусловлен следующими факторами:

1. По результатам анализа обзорных статей Общества по Вычислительному Интеллекту (*IEEE CEC*) выбранные методы входят в пятерку методов, применение которых для решения задач моделирования и классификации

описывается в наибольшем числе статей, опубликованных по результатам конференций, проводимых с участием *IEEE CEC*.

2. Существует значительное число примеров удачного использования рассматриваемых методов для идентификации и построения регрессионных моделей технологических объектов.

3. Реализация всех рассматриваемых методов в рамках единого программно-аналитического подхода позволит реализовать идею синергетического объединения разнородных информационных технологий для построения эффективных коллективных моделей технологических объектов нефтегазового комплекса.

2.1 Методы построения моделей технологических систем нефтегазового комплекса

2.1.1 Искусственные нейронные сети

Искусственные нейронные сети (далее ИНС или просто – нейронные сети) могут быть использованы для решения широкого круга практических задач, математическая постановка которых может формулироваться как постановка задачи аппроксимации функций, классификации и распознавания образов, прогнозирования, управления динамическими процессами [24-26].

В задачах аппроксимации нейронная сеть играет роль универсального аппроксиматора функции нескольких переменных. Большое число задач моделирования, идентификации и обработки сигналов формулируются именно в аппроксимационной постановке.

При решении задач прогнозирования нейронные сети используются для предсказания поведения системы по имеющимся наблюдениям ее предыдущих состояний [27]. При решении задач классификации и распознавания образов в процессе обучения нейронная сеть накапливает информацию об основных свойствах этих образов. При обобщении акцентируются отличия образов друг от друга, что и составляет основу для формирования классификационных решений [24].

В задачах управления динамическими процессами нейронная сеть используется для выполнения нескольких функций. Нейронная сеть может выступать в качестве нелинейной модели процесса и идентифицировать его основные параметры, используемые при выработке соответствующего управляющего сигнала. Сеть может также играть роль следящей системы, отслеживающей условия окружающей среды и адаптирующейся к ним. Она также может выполнять функции нейрорегулятора, заменяющего собой традиционные устройства управления [28].

В данной работе нейронные сети рассматриваются в аспекте решения задач моделирования (аппроксимации функций) и прогнозирования, при этом ИНС в соответствии с классическим подходом рассматривается как «черный ящик». Соответственно целью решения задач является получение эффективной вычислительной процедуры, а не извлечение знаний и скрытых закономерностей в явном виде. Отметим, что хотя и существуют подходы построения так называемых «логически прозрачных» ИНС [29], большой круг задач может быть эффективно решен в рамках классического подхода, рассматривающего ИНС как «черный ящик». Рассмотрим математические постановки задач моделирования и прогнозирования, а также их возможные интерпретации в аспекте использования для их решения искусственных нейронных сетей в рамках выбранного подхода.

Аппроксимация функций

Пусть имеется отображение заданное отношением

$$y = f(x), \tag{2.1}$$

где x – вектор входных переменных;

y – вектор выходных переменных.

Считается, что функция $f(\cdot)$ не известна. Имеется множество N примеров:

$$(x_i, y_i), i = \overline{1, N}. \quad (2.2)$$

Необходимо найти функцию $F(\cdot)$, отображающую вход x в выход y , которая была бы достаточно близка к функции $f(\cdot)$ в смысле Евклидовой нормы на множестве входных векторов x :

$$\|F(x) - f(x)\| < \varepsilon \text{ для всех векторов } x, \quad (2.3)$$

где ε - некоторое малое положительное число.

В терминах искусственных нейронных сетей необходимо спроектировать нейронную сеть, для которой функция $F(\cdot)$, описывающая преобразование входного сигнала в выходной сигнал в этой сети удовлетворяла бы условию (2.3).

Благодаря тому, что нейронные сети способны аппроксимировать неизвестное отображение входного пространства в выходное, они могут быть использованы для решения задач идентификации – построения математических моделей объектов, процессов или систем.

Схематично объект математического моделирования можно изобразить следующим образом:




Рисунок 2.1 – Объект математического моделирования

Здесь $x = (x_1, x_2, \dots, x_n)$ – вектор входных переменных, $y = (y_1, y_2, \dots, y_s)$ – вектор выходных переменных, $y = f(x)$ – вектор-функция.

Задача построения математической модели состоит в установлении связи между входными и выходными переменными системы или процесса в виде некоторых математических соотношений. В этом случае, множество маркированных примеров (2.2) можно использовать для обучения и проектирования нейронной сети, представляющей модель этого процесса или системы.

Нейронная сеть

Искусственной нейронной сетью называют вычислительные структуры, которые моделируют биологические процессы, обычно ассоциируемые с процессами человеческого мозга [30]. Они представляют собой распределенные и параллельные системы, способные к адаптивному обучению. В качестве элементарного преобразователя в таких сетях используется искусственный нейрон, получивший название по аналогии с биологическим прототипом.

Нейронная сеть сходна с мозгом с двух точек зрения:

- Знания поступают в нейронную сеть из окружающей среды и используются в процессе обучения.
- Для накопления знаний применяются связи между нейронами, называемые синаптическими весами.

Достаточно емко отражает принципы и механизм функционирования нейронных сетей следующее определение искусственной нейронной сети [30]: нейронная сеть – это распределенный параллельный процессор, состоящий из элементарных единиц обработки информации, накапливающих экспериментальные знания и предоставляющих их для последующей обработки.

Нейронные сети имеют ряд преимуществ перед другими методами моделирования и анализа данных. Эти преимущества обусловлены, прежде всего, способностью нейронных сетей к обобщению, т.е. способности к получению эффективного результата на данных, которые не предъявлялись в ходе обучения сети. Кроме того к важнейшим факторам, обуславливающим эф-

фективность использования нейронных сетей в системах анализа данных, можно отнести [31]:

- Внутреннее распараллеливание обработки информации в нейронных сетях.
- Нелинейность.
- Адаптивность. Нейронные сети обладают способностью адаптировать свои синаптические веса под изменение окружающей среды. В частности, нейронные сети, обученные в одной среде, могут легко быть переучены для работы в условиях колебания параметров среды. Более того при работе с нестационарными системами могут быть спроектированы нейронные сети, которые сами адаптивно изменяют синаптические веса в реальном времени.
- Отказоустойчивость. Ввиду распределенного характера хранения информации в нейронной сети, можно утверждать, что только серьезное нарушение структуры сети приведет к существенному падению ее работоспособности. Это особенно актуально при реализации нейронных сетей в электронных схемах и т.п.
- Единообразие проектирования и анализа. Нейронные сети можно считать универсальным методом обработки, анализа информации. Это позволяет использовать одни и те же теории и алгоритмы обучения вне зависимости от области применения систем, реализующих обработку данных нейронными сетями.
- Все это делает нейронные сети мощным инструментом моделирования и анализа данных в целом, позволяет использовать их в качестве инструментов для решения сложных, масштабных задач, которые трудно или вообще не решаются другими методами.

Искусственный нейрон

Единицей обработки информации в нейронной сети является нейрон. В ИНС нейрон является приближенной моделью биологического нейрона и

имитирует его функционирование. В модели нейрона можно выделить три основные составляющие, определяющие его функциональные возможности [24]:

Набор синаптических связей – набор связей, по которым передается сигнал к нейрону от других нейронов сети. Входной сигнал при прохождении через синапс умножается на число, называемое синаптическим весом и характеризующее силу связи. В отличие от синапсов мозга, синаптический вес искусственного нейрона может иметь как положительное, так и отрицательное значение.

Сумматор – рассчитывает взвешенную сумму входных сигналов нейрона в соответствии с весами соответствующих синапсов. Таким образом, на выходе сумматора формируется линейная комбинация входных сигналов, поступающих к нейрону.

Функция активации или передаточная функция – функция одного аргумента, определяющая зависимость выходного сигнала нейрона от взвешенной суммы сигналов на его входах.

Математическая модель нейрона

Одна из первых моделей нейрона была предложена У. МакКалокком и В. Питсом в 1943 году [32]. Изначально, в этой модели нейрон считался бинарным элементом, то есть функционировал в соответствии с правилом «все или ничего», а его выходной сигнал принимал лишь двоичные выходные значения: 0 или 1.

Рассмотрим модель МакКалока-Питса подробнее. В ней входные сигналы нейрона суммируются с учетом соответствующих весов в сумматоре, после чего результат сравнивается с пороговым значением. Выходной сигнал нейрона определяется при этом зависимостью:

$$output = f(\sum_{i=1}^n w_i \times input_i). \quad (2.4)$$

где *output* – выходной сигнал нейрона;

input_i – входной сигнал нейрона с *i*-го синапса;

w_i – весовой коэффициент на i -м синапсе;

n – общее число синапсов рассматриваемого нейрона.

Функция f – активационная функция. В модели МакКаллока-Питса в качестве активационной функции использовалась пороговая функция – функция единичного скачка:

$$f(v) = \begin{cases} 1, & \text{если } v \geq 0; \\ 0, & \text{если } v < 0. \end{cases} \quad (2.5)$$

На ранних стадиях использовались и другие пороговые функции, однако на сегодняшний день в большинстве работ используются сигмоидальные активационные функции. Введение сигмоидальной активационной функции было обусловлено ограниченностью нейронных сетей с пороговыми функциями активации. Примером сигмоидальной функции может служить нелинейная функция активации с насыщением – логистическая функция, определяемая выражением вида:

$$f(v) = \frac{1}{1 + \exp(-\alpha v)}, \quad (2.6)$$

где α – параметр наклона сигмоидальной функции.

При уменьшении α сигмоид становится более пологим, в пределе при $\alpha = 0$ вырождаясь в горизонтальную линию на уровне 0,5. При увеличении параметра наклона α сигмоидальная функция приближается по внешнему виду к пороговой функции. Выходное значение для нейрона, в котором в качестве активационной функции используется логистическая, лежит в диапазоне $[0,1]$. Для многих алгоритмов обучения искусственных нейронных сетей важным полезным свойством сигмоидальной активационной функции является ее дифференцируемость [33]. Другим распространенным вариантом сигмоидальной активационной функции является гиперболический тангенс:

$$f(v) = \tanh(v). \quad (2.7)$$

Диапазон выходных значений для нейрона с такой активационной функцией лежит в диапазоне $[-1; 1]$, что оказывается полезным при решении ряда задач [24].

Для решения прикладных задач используются и другие активационные функции [34], наиболее распространенные из которых приведены в таблице 2.1.

Таблица 2.1 – Часто используемые активационные функции

Название	Формула	Область значений
Линейная	$f(v) = kv$	$(-\infty, \infty)$
Экспоненциальная	$f(v) = e^{av}$	$(0, \infty)$
Синусоидальная	$f(v) = \sin(v)$	$(-1, 1)$
Линейная с насыщением	$f(v) = \begin{cases} -1, & v \leq -1 \\ s, & -1 < v < 1 \\ 1, & v \geq 1 \end{cases}$	$(-1, 1)$
Пороговая	$f(v) = \begin{cases} 0, & v < 0 \\ 1, & v \geq 0 \end{cases}$	$(0, 1)$
Сигмоидальная рациональная	$f(v) = \frac{v}{a + v }$	$(-1, 1)$
Модульная	$f(v) = v $	$(0, \infty)$
Квадратичная	$f(v) = v^2$	$(0, \infty)$
Знаковая	$f(v) = \begin{cases} -1, & v \leq 0 \\ 1, & v > 0 \end{cases}$	$(-1, 1)$

Многослойный персептрон

Существует большое число различных типов топологий нейронных сетей, но в примерно 80% из всех реальных приложений используются многослойные полносвязные сети прямого распространения – многослойные персептроны [35].

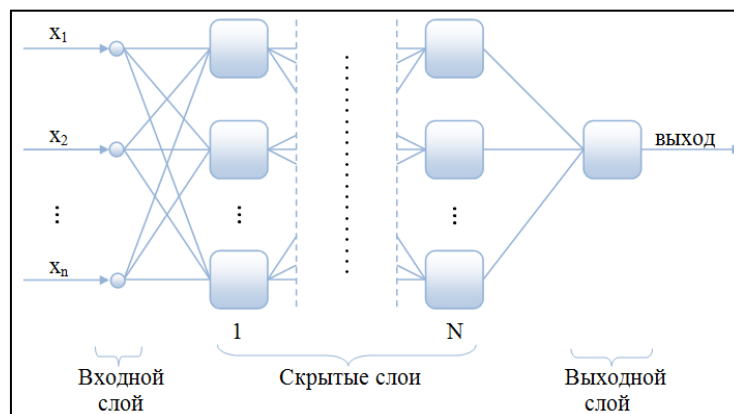


Рисунок 2.2 – Многослойный персептрон

На рисунке 2.2 изображен многослойный персептрон с n входами, одним выходом и N скрытыми слоями.

Алгоритмы обучения нейронных сетей

Способность нейронных сетей к обучению на основе данных, поступающих из окружающей среды, является, пожалуй, их самым важным и полезным свойством. *Обучением* нейронной сети называется процесс, в ходе которого свободные параметры нейронной сети настраиваются посредством моделирования среды, в которую эта сеть встроена. Тип обучения определяется способом подстройки этих параметров [24]. Обычно, обучение нейронных сетей подразумевает итеративный процесс настройки весовых коэффициентов, состоящий из следующей последовательности шагов:

1. В нейронную сеть поступают стимулы из внешней среды.
2. В результате этого изменяются свободные параметры сети.
3. После изменения внутренних параметров нейронная сеть отвечает на возбуждение уже иным образом.

Единого универсального алгоритма, подходящего для настройки всех архитектур нейронных сетей, не существует, а существует множество алгоритмов обучения, каждый из которых имеет свои достоинства и недостатки. Основные отличия алгоритмов обучения нейронных сетей заключаются в ис-

пользовании различных способов настройки синаптических весов и различных способов связи обучаемой сети с внешней средой.

Различные подходы к обучению нейронных сетей можно разделить на три вида:

1. Обучение с учителем. Обучение с учителем основано на прямом сравнении между желаемым сигналом и текущим откликом сети. Параметры сети корректируются в соответствии с учетом обучающего вектора и сигнала ошибки, характеризующего рассогласование между желаемым сигналом сети и ее текущим откликом. Часто обучение с учителем сводится к задаче минимизации функции ошибки, вид которой определяется в зависимости от типа решаемой задачи [36].

2. Обучение без учителя. При использовании такого подхода в процессе обучения не существует примеров с «истинными значениями» выхода, по которым проводится обучение. Существует лишь независимая от задачи мера качества представления, которому должна обучиться нейронная сеть. Свободные параметры сети оптимизируются по отношению к этой мере [37].

3. Обучение с подкреплением (reinforcement learning) [38].

Далее в работе рассматриваются алгоритмы, соответствующие подходу обучения с учителем, и задачи, в которых соответственно применим данный подход. Однако, общие моменты, связанные с проектированием нейронных сетей и их коллективов могут быть легко расширены на задачи, для которых традиционно применяются другие виды обучения.

Как уже упоминалось, настройка весовых коэффициентов сети обычно формулируется как задача минимизации функции ошибки, например, минимизации среднеквадратичной ошибки. Для решения задачи минимизации функции ошибки в большинстве алгоритмов обучения используются методы, основанные на градиентном спуске. К таким методам можно отнести алгоритм обратного распространения ошибки или метод сопряженных градиентов. Существуют примеры удачного использования алгоритма обратного

распространения ошибки для решения задачи настройки весовых коэффициентов нейронных сетей, используемых в различных областях [39-40].

Однако данный метод, как и большинство других методов, основанных на градиентном спуске, обладает рядом недостатков [41]. Ввиду того, что поверхность графика функции ошибки сложной сети сильно изрезана, функция имеет сложный нелинейный характер с множеством оврагов, поиск с помощью метода обратного распространения ошибки и других подобных методов часто останавливается при попадании в локальный минимум. Поиск глобального минимума становится невозможным ввиду мультимодальности и/или недифференцируемости функции ошибки.

Одним из путей для преодоления недостатков методов обучения, основанных на градиентном спуске, является адаптация и использование для настройки весовых коэффициентов ИНС генетических алгоритмов [42].

2.1.2 Многомерные адаптивные регрессионные сплайны

Многомерные адаптивные регрессионные сплайны (МАР-сплайны) были впервые предложены Фридманом в 1991 г. [43] для решения регрессионных задач и задач классификации, в которых требуется предсказать значения набора зависимых переменных по набору независимых переменных. Данный метод является непараметрической процедурой, не использующей в своей работе никаких предположений о виде функциональной зависимости между зависимыми и независимыми переменными. МАР-сплайны задаются базисными функциями и набором коэффициентов, полностью определяемых по данным. МАР-сплайны находят свое применение во многих сферах науки и технологий, напри мер, в предсказании видов распределений по имеющимся данным кишечного поглощения лекарств, а также в воспроизведении речи и поиске глобального оптимума в проектировании конструкций [44-47]. Метод МАР-сплайнов находит искомую зависимость за 2 стадии: «вперед» (forward stage) и «назад» (backward stage) [48]. Первая стадия заключается в добавлении базисных функций к набору, пока не будет достигнут макси-

мальный уровень сложности. На второй стадии из набора удаляются функции, которые вносят наименьший вклад в ошибку.

Описание работы алгоритма

Дана регрессионная выборка:

$$D = \{\bar{x}_i, y_i\}, \quad (2.8)$$

где $x_i \in R^p, i = \overline{1, N}$ – векторы независимой переменной;

$y_i \in R, i = \overline{1, N}$ – значения зависимой переменной (непрерывные или бинарные).

Связь между y_i и x_i может быть представлена в виде:

$$y_i = f(x_i^1, x_i^2, \dots, x_i^p) + \varepsilon, \quad (2.9)$$

где f — неизвестная функция;

ε — ошибка.

В одномерном случае МАР-сплайны выражаются через кусочно-линейные базисные функции, $(x - t)_+$ и $(t - x)_+$ с узлом в t . Данные функции являются усеченными линейными функциями, при $x \in R$:

$$\begin{aligned} (x - t)_+ &= \begin{cases} x - t, & \text{если } x > t; \\ 0, & \text{иначе,} \end{cases} \\ (t - x)_+ &= \begin{cases} t - x, & \text{если } x < t; \\ 0, & \text{иначе,} \end{cases} \end{aligned} \quad (2.10)$$

Эти функции также называются отраженной парой (*reflected pair*). В многомерном случае для каждой компоненты x^j вектора $\bar{x} = (x^1, \dots, x^j, \dots, x^p)^T$ строятся отраженные пары с узлами в каждой наблюдаемой переменной x_i^j ($i = \overline{1, N}; j = \overline{1, p}$). Таким образом, набор построенных функций может быть представлен в виде:

$$C = \{(x^j - t)_+, (t - x^j)_+ \mid t \in \{x_1^j, x_2^j, \dots, x_N^j\}, j \in \{1, 2, \dots, p\}\}. \quad (2.11)$$

Если все входные данные различны, то в наборе $2Np$ функций, причем каждая из них зависит только от одной переменной x^j .

Используемые для аппроксимации базисные функции выглядят следующим образом:

$$B_m(\bar{x}) = \prod_{k=1}^{K_m} [s_{km} \cdot (x^{v(km)} - t^{km})]_+, \quad (2.12)$$

где K_m — общее число усеченных линейных функций в m -ой базисной функции;

$x^{v(km)}$ — компонента вектора \bar{x} , относящаяся к k -ой усеченной линейной функции в m -ой базисной функции;

t^{km} — соответствующий узел, а $s_{km} \in \{\pm 1\}$.

Построенная модель, как и в линейной регрессии, представляет собой линейную комбинацию, отличие состоит в том, что кроме входных переменных разрешается использовать функции из набора C и их производные функции. Таким образом, модель имеет вид:

$$y = \hat{f}(\bar{x}) + \varepsilon = c_0 + \sum_{m=1}^M c_m B_m(\bar{x}) + \varepsilon, \quad (2.13)$$

где M — число базисных функций в рассматриваемой модели;

c_0 — общий коэффициент.

Как и в линейной регрессии, задав B_m , коэффициенты c_m могут быть найдены по методу наименьших квадратов. Самое главное в данной модели — это выбор базисных функций. Первоначально модель содержит единственную функцию $B_0(\bar{x}) = 1$, а все функции из набора C являются возможными кандидатами для включения в модель.

К примеру, следующие функции могут быть базисными:

- 1,
- x^j ,
- $(x^j - t^k)_+$,
- $x^l x^j$,
- $(x^j - t^k)_+ + x^l$,
- $(x^j - t^k)_+ (x^l - t^h)_+$.

В данном алгоритме каждая базисная функция зависит от разных переменных. Это означает, что $l \neq j$ в базисных функциях, указанных выше. На каждом шаге новая пара базисных функций является произведением функции $B_m(\bar{x})$ из множества моделей M на одну из отраженных пар множества C .

В конце данной процедуры построена большая модель, которая включает в себя некоторые излишние переменные и обычно чрезмерно подгоняет данные. Необходимо проведение стадии «назад», которая заключается в следующем: на каждом шаге удаляется функция, отсутствие которой вызывает наименьшее увеличение суммы квадратов невязок (RSS). Таким образом, для каждого размера M строится наилучшая модель $\hat{f}(M)$. Для оценки оптимальной величины M используется процедура обобщенного скользящего контроля (*generalized cross-validation*). Данный критерий (также известный как *lack-of-fit criterion*) выглядит следующим образом [44]:

$$LOF \hat{f}_M = GCV(M) = \frac{1}{N} \sum_{i=1}^N \left(y_i - \hat{f}_M(x_i) \right)^2 / (1 - C(M)/N)^2, \quad (2.14)$$

где N – число исходных данных;

$C(M)$ – оценка штрафов в модели, содержащей M базисных функций.

$C(M)$ – число параметров, подлежащих определению. Один из способов задания числа параметров:

$$C(M) = r + cK. \quad (2.15)$$

Число линейно-независимых базисных функций в модели обозначено r , число узлов, выбранных в стадии «вперед» – K , а число c показывает оценку оптимизации каждой из базисных функций. В общем случае, $c = 3$, но если используемая модель является аддитивной, то $c = 2$. Чем меньше $C(M)$, тем больше получаемая модель и больше число базисных функций, и наоборот соответственно. GCV представляет собой средний квадрат невязок умноженных на коэффициент, характеризующий сложность модели. Таким образом, наилучшая модель состоит из M^* базисных функций, где M^* – решение задачи минимизации $LOF \hat{f}_M$ [49]:

$$M^* = \operatorname{argmin}_M LOF \hat{f}_M. \quad (2.16)$$

Особенность метода MAP-сплайнов заключается в использовании кусочно-линейных базисных функций и определенном способе построения модели. Главным свойством кусочно-линейных функций является их способность действовать локально, т. е. принимать ненулевые значения лишь на части их области определения. Результат умножения одной функции на другую отличен от нуля лишь в малой части пространства, где обе функции принимают ненулевые значения. Это и позволяет строить качественные модели, используя сплайны. Если же в качестве базисных функций использовать полиномы, то результат будет хуже по причине того, что полиномы отличны от нуля во всем пространстве.

Данный метод эффективен не только при рассмотрении функций одной переменной, но и в многомерных пространствах.

2.1.3 Деревья регрессии и классификации

Метод деревьев решений (decision trees) является одним из наиболее популярных методов решения задач классификации и прогнозирования. Иногда этот метод Data Mining также называют деревьями решающих правил, деревьями классификации и регрессии.

Как видно из последнего названия, при помощи данного метода решаются задачи классификации и прогнозирования.

Если зависимая, т.е. целевая переменная принимает дискретные значения, при помощи метода дерева решений решается задача классификации.

Если же зависимая переменная принимает непрерывные значения, то дерево решений устанавливает зависимость этой переменной от независимых переменных, т.е. решает задачу численного прогнозирования.

Впервые деревья решений были предложены Ховилендом и Хантом в конце 50-х годов прошлого века. Самая ранняя и известная работа Ханта и др., в которой излагается суть деревьев решений – «Эксперименты в индукции» - была опубликована в 1966 году. Атрибуты набора данных могут иметь как дискретное, так и числовое значение.

Алгоритм CART предназначен для построения бинарного дерева решений. Бинарные деревья также называют двоичными. Другие особенности алгоритма CART:

- функция оценки качества разбиения;
- механизм отсечения дерева;
- алгоритм обработки пропущенных значений;
- построение деревьев регрессии.

Каждый узел бинарного дерева при разбиении имеет только двух потомков, называемых дочерними ветвями. Дальнейшее разделение ветви зависит от того, много ли исходных данных описывает данная ветвь. На каждом шаге построения дерева правило, формируемое в узле, делит заданное множество примеров на две части. Правая его часть (ветвь right) - это та часть

множества, в которой правило выполняется; левая (ветвь left) - та, для которой правило не выполняется.

Функция оценки качества разбиения

Функция оценки качества разбиения используется для выбора оптимального правила, - индекс Gini. Данная оценочная функция основана на идее уменьшения неопределенности в узле. Допустим, есть узел, и он разбит на два класса. Максимальная неопределенность в узле будет достигнута при разбиении его на два подмножества по 50 примеров, а максимальная определенность - при разбиении на 100 и 0 примеров.

При помощи этого индекса атрибут выбирается на основании расстояний между распределениями классов.

Если дано множество T , включающее примеры из n классов, индекс Gini, т.е. $gini(T)$, определяется по формуле:

$$Gini(c) = 1 - \sum_{i=1}^n p_i^2, \quad (2.17)$$

где c – текущий узел;

p_j – вероятность класса j в узле c ;

n – количество классов.

Правила разбиения

Алгоритм CART работает с числовыми и категориальными атрибутами. В каждом узле разбиение может идти только по одному атрибуту. Если атрибут является числовым, то во внутреннем узле формируется правило вида:

$$x_i \leq c. \quad (2.18)$$

Значение c в большинстве случаев выбирается как среднее арифметическое двух соседних упорядоченных значений переменной x_i обучающего

набора данных. Если же атрибут относится к категориальному типу, то во внутреннем узле формируется правило $V(x_i)$ - некоторое непустое подмножество множества значений переменной x_i в обучающем наборе данных.

Механизм отсечения

Этим механизмом, имеющим название *minimal cost-complexity tree pruning*, алгоритм CART принципиально отличается от других алгоритмов конструирования деревьев решений. В рассматриваемом алгоритме отсечение - это некий компромисс между получением дерева «подходящего размера» и получением наиболее точной оценки классификации. Метод заключается в получении последовательности уменьшающихся деревьев, но деревья рассматриваются не все, а только «лучшие представители».

Перекрестная проверка (*V-fold cross-validation*) является наиболее сложной и одновременно оригинальной частью алгоритма CART. Она представляет собой путь выбора окончательного дерева, при условии, что набор данных имеет небольшой объем или же записи набора данных настолько специфические, что разделить набор на обучающую и тестовую выборку не представляется возможным.

Итак, основные характеристики алгоритма CART: бинарное расщепление, критерий расщепления - индекс *Gini*, алгоритмы *minimal cost-complexity tree pruning* и *V-fold cross-validation*, принцип «вырастить дерево, а затем сократить», высокая скорость построения, обработка пропущенных значений.

2.1.3 Метод генетического программирования для задач символьной регрессии

Пусть имеются наблюдения входных и выходных переменных исследуемого процесса $V = (x_i, y_i)$, $i = \overline{1, n}$, n – объем выборки наблюдений. Известно, что существует зависимость $y = f(x)$, связывающая входные и выходные переменные исследуемого процесса, однако, вид и структура зависимости не известны.

Необходимо по имеющейся выборке наблюдений V найти в символьной форме математическое выражение $\hat{y} = \hat{f}(x)$, аппроксимирующее зависимость между входными и выходными переменными. Символьное математическое выражение (формула, связывающая входные и выходные параметры процесса) должно по возможности наиболее точно соответствовать реальной зависимости.

Критерий оптимальности

В качестве критерия оптимальности может быть использована, например, величина относительной средней ошибки моделирования по обучающей выборке:

В абсолютных величинах:

$$W = \frac{1}{n(y^{max} - y^{min})} \sum_{i=1}^n |\hat{y}(x_i) - y_i|. \quad (2.19)$$

В процентах:

$$W = \frac{100\%}{n(y^{max} - y^{min})} \sum_{i=1}^n |\hat{y}(x_i) - y_i|, \quad (2.20)$$

где i – номер наблюдения в выборке; $i = \overline{1, n}$;

y^{max} и y^{min} – максимальное и минимальное значение выходного параметра соответственно.

Решение практических задач предполагает разбиение исходной выборки V на обучающую и экзаменующую выборки. В этом случае значение критерия оптимальности при настройке модели вычисляется по обучающей выборке, при оценке качества полученной модели – по экзаменующей выборке.

На современном этапе методы решения задачи символьной регрессии не разработаны достаточно хорошо. Генетическое программирование – один из самых многообещающих подходов в данном направлении. Символьная ре-

грессия позволяет получить не только вычислительную процедуру, но и формулу (символьное математическое выражение), которую можно подвергнуть содержательному анализу, упростить, а затем и уточнить.

Основная идея, на которой основан метод генетического программирования, состоит в том, чтобы с помощью программной реализации процедур, имитирующих эволюционные процессы, из случайно сгенерированного множества функциональных зависимостей, получить зависимость, хорошо описывающую данные, представленные в исходных выборках [50].

Представление решений в генетическом программировании

В отличие от генетических алгоритмов, в которых индивиды в популяции представляют собой символьные (в частности бинарные) строки, кодирующие решение, решения в генетическом программировании могут быть представлены в различной форме и иметь различный размер. Чаще всего используется представление решений в виде деревьев [51].

Дерево – направленный граф, в котором каждая последующая вершина связана с одной и только одной предыдущей. Множество всех возможных внутренних вершин дерева называется *функциональным множеством*. Множество всех возможных внешних вершин дерева называется *терминальным множеством*. Элементами функционального множества обычно выбираются операции и функции. В качестве элементов терминального множества рассматриваются входные данные – переменные и константы. Пример представления решения в методе генетического программирования представлен на рисунке 2.3.

Решение поставленной задачи методом генетического программирования возможно, если функциональное множество F и терминальное множество T удовлетворяют свойствам замкнутости и достаточности.

Замкнутость предполагает, что любой элемент множества F в качестве аргумента может принимать любой элемент множества T .

Для выполнения свойства достаточности необходимо, чтобы элементы множества T были выбраны так, чтобы решение задачи было бы возможным.

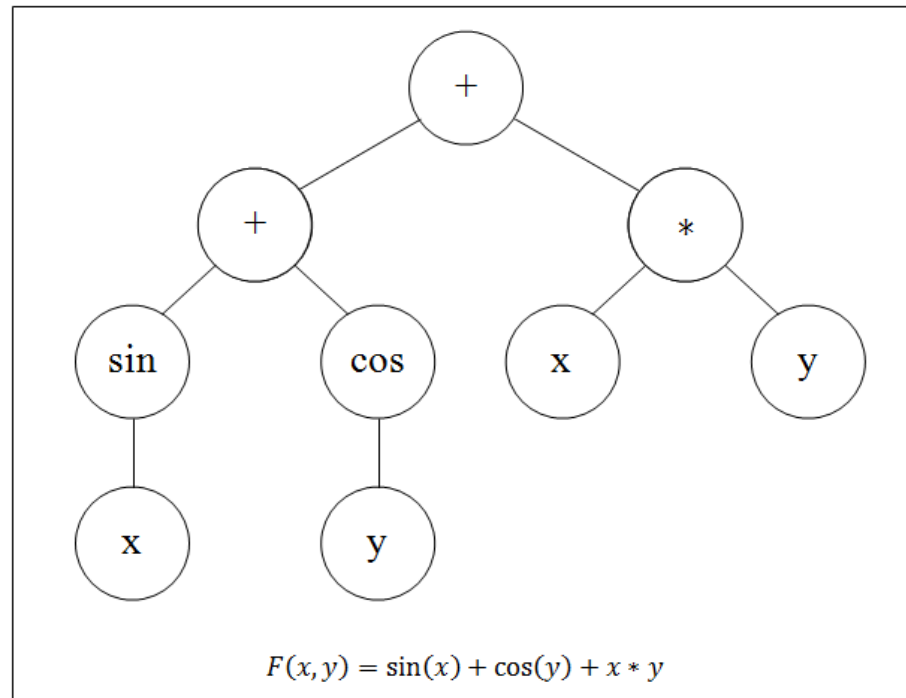


Рисунок 2.3 – Пример представления решения в генетическом программировании

Инициализация начальной популяции

Для инициализации начальной популяции необходимо задать принцип, по которому будут генерироваться решения, включаемые в нее, т.е. выбрать один из возможных методов выращивания деревьев:

- **Полный метод.** Задается максимальная глубина дерева d . Все вершины дерева на глубине, меньшей, чем d , заполняются случайным образом элементами функционального множества F . Все вершины на глубине d заполняются случайным образом элементами терминального множества T . Дерево, сгенерированное таким образом, представляет собой полное дерево глубины d .

- **Метод выращивания.** Задается максимальная глубина дерева d . Вершины дерева на глубине, меньшей, чем d , случайным образом заполняются элементами из функционального множества F или из терминального множества T (в этом случае рост данной ветви заканчивается). Вершины на

глубине d заполняются случайным образом элементами терминального множества T .

Функция пригодности

В методе генетического программирования функция пригодности представляет собой оценку приспособленности решения и является критерием отбора решений из текущей популяции для создания следующих поколений решений. Решениям, имеющим большую приспособленность, соответствует большее значение функции пригодности. Таким образом, пригодность является движущей силой моделируемого естественного отбора.

Критерий останова

В качестве критерия останова может быть использовано одно из следующих правил:

1. Достигнута заданная точность – значения ошибок аппроксимации, вычисленных по экзаменуемой и обучающей выборкам, меньше заданных.
2. Выполнено заданное число итераций (достигнуто заданное число поколений).

Решение задачи символьной регрессии методом генетического программирования

Перед использованием алгоритма, реализующего процедуру генетического программирования, необходимо выполнить следующие подготовительные шаги:

1. Определить терминальное множество T – множество термов, из которых будут строиться решения. Для задачи символьной регрессии множество T включает в себя набор переменных x_i , $i = \overline{1, n}$, где n – размерность задачи и набор констант.

Определить функциональное множество F – множество функций, из которых будут строиться решения задачи. Решая задачу, исследователь выбирает компоненты функционального множества, исходя из своих априорных предположений о комбинациях функций, которые могли бы содержаться

в решении. В качестве элементов функционального множества могут быть использованы следующие функции:

- Арифметические операции $\{+, -, \times, \div\}$.
- Математические функции $\{\sin, \cos, \ln, \exp$ и др. $\}$
- Булевы операции.

2. Задать функцию пригодности. Значения функции пригодности f могут быть вычислены, например, следующим образом:

$$f_i = \frac{1}{1 + error_i} - K \cdot N, i = \overline{1, n}, \quad (2.21)$$

где N – число вершин в дереве, которым представлено решение;

K – коэффициент штрафа за длину дерева;

$error_i$ – средняя абсолютная ошибка, вычисляемая по формуле:

$$error_i = \frac{1}{n} \sum_{j=1}^n |\hat{y}_j^i - y_j|, \quad (2.22)$$

где n – объем выборки;

\hat{y}_j^i – значение в точке \bar{x}_j , вычисленное с помощью рассматриваемого i – го индивида;

y_j – значение в соответствующей точке выборки.

3. Задать параметры, определяющие выполнение шагов алгоритма:

- размер популяции,
- метод инициализации начального поколения,
- вероятность и тип скрещивания,
- вероятность и тип мутации и т.д.

4. Выбрать критерий останова.

После выполнения подготовительных шагов запускается алгоритм, реализующий генетическое программирование, общая схема которого не зависит от вида решаемой задачи.

Общая схема метода генетического программирования

1. Алгоритм генетического программирования начинается с инициализации начальной популяции решений.

2. Пока не будет выполнен критерий останова, выполняется итерационная процедура, состоящая из следующих шагов:

2.1. С помощью функции пригодности для каждого из индивидов текущего поколения вычисляется значение пригодности.

2.2. С вероятностью, связанной с найденным значением пригодности, выбирается один или несколько индивидов из популяции для выполнения генетических операций, описанных в шаге 2.3.

2.3. Создается новая популяция индивидов-программ с помощью выполнения с заданной вероятностью следующих генетических операторов:

2.3.1. Создание нового индивида с помощью скрещивания.

2.3.2. Создание нового индивида с помощью мутации.

2.3.3. Простое копирование индивида в новое поколение.

3. После того, как будет выполнен критерий останова, лучшее решение найденное в ходе выполнения алгоритма объявляется результатом работы алгоритма.

В случае удачного выполнения алгоритма, полученный результат может являться решением или достаточно хорошим приближением решения задачи.

Блок схема метода генетического программирования представлена на рисунке 2.4.

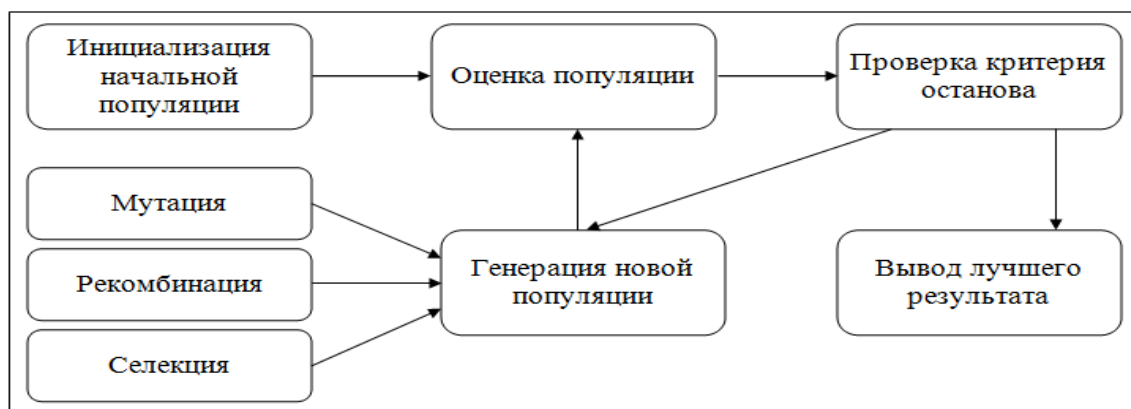


Рисунок 2.4 – Блок-схема метода генетического программирования

2.1.4 Непараметрическая идентификация

Параметрическая идентификация предполагает наличие фиксированной структуры модели системы. Выбор структуры того или иного вида обычно основывается на априорных сведениях о процессах, протекающих в рассматриваемой системе, либо на основе успешного применения такого вида структур при моделировании подобных систем. Качество моделирования в этом случае зависит от «правильности» априорного выбора структуры.

Однако во многих случаях априорная информация о процессе, объекте, системе практически отсутствует, и нет каких-либо оснований, позволяющих однозначно судить о структуре модели. В этих условиях методы параметрической идентификации не применимы.

В этих случаях могут быть применены методы, основанные на стохастических аппроксимациях непараметрического вида, - методы непараметрической идентификации. Методы непараметрической идентификации позволяют достаточно хорошо решать задачу восстановления зависимостей, аппроксимирующих данные в исходной выборке наблюдений за объектом. Непараметрические методы восстановления функции по наблюдениям не связаны с априорным выбором вида аппроксимирующей функции и относятся к методам локальной аппроксимации. Непараметрические оценки сходятся к искомым вероятностным характеристикам, например к кривой регрессии, в

отличие от параметрических аппроксимаций, где речь идет о сходимости параметров в принятых структурах.

Как и в большинстве численных методов идентификации, при непараметрическом подходе для аппроксимации экспериментальных (статистических) данных используются регрессионные модели. Регрессия - это оценка функциональной зависимости условного среднего значения результативного признака Y от факторных признаков (x_1, x_2, \dots, x_N) , т.е. регрессия – это некоторая усредненная количественная зависимость между выходными и входными переменными:

$$y(x) = f(x) = M\{y/x\} = \int_{-\infty}^{\infty} yp(y/x)dy. \quad (2.23)$$

Чтобы получить непараметрическую оценку регрессии необходимо оценить неизвестную условную плотность распределения:

$$p(y/x) = \frac{p(x, y)}{p(x)}. \quad (2.24)$$

Для этого оценим совместную плотность распределения $p(x, y)$, используя оценку Розенבלата-Парзена:

$$p_s(x, y) = \frac{1}{s} \sum_{i=1}^s \frac{1}{C_s^y} \Phi\left(\frac{y - y_i}{C_s^y}\right) \frac{1}{C_s^x} \Phi\left(\frac{x - x_i}{C_s^x}\right). \quad (2.25)$$

Тогда, с учетом условия:

$$\frac{1}{C_s^y} \int_{\Omega(y)} y \Phi\left(\frac{y - y_i}{C_s^y}\right) dy = y_i, \quad i = \overline{1, s}, \quad (2.26)$$

непараметрическая оценка условного математического ожидания примет вид:

$$y_s(x) = \frac{\sum_{i=1}^s y_i \Phi\left(\frac{x-x_i}{C_s}\right)}{\sum_{i=1}^s \Phi\left(\frac{x-x_i}{C_s}\right)}. \quad (2.27)$$

Ядерная оценка регрессии (2.27) носит имя Надарая-Ватсона. Доказаны теоремы об асимптотических свойствах этой оценки.

Основная идея, легшая в основу (2.27) состоит в придании относительно большего веса наблюдениям, ближайшим к оцениваемой точке, в смысле расстояния, определяемого ядром $\Phi(\cdot)$ [52,53]. Оценку (2.27) можно получить и формально – заменой вероятностных характеристик в выражении условного математического ожидания их ядерными аналогами. Степень гладкости непараметрической оценки регрессии зависит от степени гладкости ядра $\Phi(\cdot)$ и от величины параметра C_s .

Колоколообразная функция $\Phi(\cdot)$ должна удовлетворять следующим условиям:

1. $\Phi(z) < \infty, \forall z \in \Omega(z)$,
2. $\int_{\Omega(z)} \Phi(z) dz = 1$,
3. $\int_{\Omega(z)} \Phi^2(z) dz < \infty$,
4. $\lim_{s \rightarrow \infty} \frac{1}{C_s} \Phi\left(\frac{x-t}{C_s}\right) = \delta(x-t)$, здесь $\delta(x)$ – дельта-функция Дирака.

На параметр C_s накладываются следующие ограничения, обеспечивающие сходимость непараметрической процедуры:

1. $\forall s \in \Omega(s), C_s > 0$,
2. $\lim_{s \rightarrow \infty} C_s = 0$,
3. $\lim_{s \rightarrow \infty} s C_s = \infty$.

Для многомерного случая оценка (2.27) имеет вид:

$$y_s^k(x_1, \dots, x_n) = \frac{\sum_{i=1}^s y_i^k \prod_{j=1}^n \Phi\left(\frac{x^j - x_i^j}{C_s^j}\right)}{\sum_{i=1}^s \prod_{j=1}^n \Phi\left(\frac{x^j - x_i^j}{C_s^j}\right)}, \quad k = \overline{1, m} \quad (2.28)$$

В качестве функции $\Phi(\cdot)$ могут быть использованы ядра следующего вида:

1. Прямоугольное ядро:

$$\Phi(z) = \begin{cases} 0.5, & |z| \leq 1 \\ 0, & |z| > 1 \end{cases}. \quad (2.29)$$

2. Треугольное ядро:

$$\Phi(z) = \begin{cases} 1 - |z|, & \text{если } |z| \leq 1 \\ 0, & \text{если } |z| > 1 \end{cases}. \quad (2.30)$$

3. Параболическое ядро:

$$\Phi(z) = \begin{cases} 0.335 - 0.067z^2, & \text{если } z^2 \leq 5 \\ 0, & \text{если } z^2 > 5 \end{cases}. \quad (2.31)$$

4. Экспоненциальное ядро:

$$\Phi(z) = \begin{cases} 0.05968(e^z + e^{-z}) - 0.154293z^2 + 0.2311, & \text{если } |z| \leq 2.6 \\ 0, & \text{если } |z| > 2.6 \end{cases}. \quad (2.32)$$

5. Ядро вида:

$$\Phi(z) = \begin{cases} \frac{\sqrt{\pi^2 - 8}}{4} \cos\left(\frac{\sqrt{\pi^2 - 8}}{4} z\right), & \text{если } |z| \leq \frac{\sqrt{\pi^2 - 8}}{4} \\ 0, & \text{если } |z| > \frac{\sqrt{\pi^2 - 8}}{4} \end{cases}. \quad (2.33)$$

Исследование влияния вида колоколообразных функций на точность оценивания привело к выводу, что вид этих функций незначительно влияет на точность аппроксимаций. Поэтому для облегчения расчетов можно брать любой вид ядра, в том числе и треугольный, параболический и другие, широко применяемые в непараметрическом оценивании, при условии, что они удовлетворяют выше приведенным условиям сходимости.

Тем не менее, оптимальной формой ядра $\Phi(\cdot)$ является усеченная парабола:

$$\Phi(z) = \begin{cases} 0.335 - 0.067z^2, & \text{если } z^2 \leq 5 \\ 0, & \text{если } z^2 > 5 \end{cases}. \quad (2.34)$$

Выбор оптимального параметра размытости C_s , осуществляется путем минимизации среднеквадратичного критерия по параметру C_s . Среднеквадратичный критерий имеет вид

$$W(C_s) = \frac{1}{s} \sum_{i=1}^s (y_i - y_{si}(x, C_s))^2 \rightarrow \min_{C_s}. \quad (2.35)$$

Непараметрические алгоритмы адаптации при активном накоплении информации

2.1.5 Непараметрические алгоритмы адаптации при активном накоплении информации

Процесс активного накопления информации позволяет интенсифицировать процесс обучения. В общих чертах можно сказать, что алгоритмы

адаптации здесь имеют черты дуализма, и состоят из двух слагаемых, характеризующих «знание» и «поиск». Часть алгоритма, в которой аккумулируется «знание» совпадает с соответствующим алгоритмом при пассивном накоплении информации, вторая «поисковая» часть играет доминирующую роль на тех этапах, когда система еще не «обучена» [54].

Итак, пусть наблюдения (u, q) поступают в адаптивную систему последовательно, т. е. сначала $(u[1], q[1])$, затем $(u[2], q[2])$ и т. д. Процесс восстановления $\hat{r}(w) = M\{r/w(u)\}$ осуществляется также последовательно и носит активный характер. В этом случае алгоритм оценивания $\hat{r}^{\text{опт}}(w)$ выглядит следующим образом:

$$\hat{r}^{\text{опт}}(s + 1) = \hat{r}^{\text{опт}*}(s) + \Delta r(s + 1), \quad (2.36)$$

где

$$\hat{r}^{\text{опт}*}(s) = \frac{\sum_{t=1}^s \hat{r}^{\text{опт}}(t) \Phi\left(\frac{w(u) - w(u(t))}{c_s}\right)}{\sum_{t=1}^s \Phi\left(\frac{w(u) - w(u(t))}{c_s}\right)}, \quad (2.37)$$

а $\Delta r(s + 1)$ - поисковые шаги, обеспечивающие активное накопление информации.

Первое слагаемое в выражении (2.36) $\hat{r}^{\text{опт}*}$ представляет собой член в $\hat{r}^{\text{опт}}$, в котором сосредотачиваются «знания» об объекте, т.е. оценка $\hat{r}^{\text{опт}*}$ представляет собой модель оптимального оператора $\hat{r}^{\text{опт}}$. Поскольку обучающей выборки на начальном этапе обучения нет, а есть лишь отдельные ее точки, поступающие в обучающуюся систему, то этот темп обучения существенно зависит от поисковых шагов Δr . Таким образом, Δr «сосредотачивается способность» системы к приведению объекта к цели. Это демонстрирует дуальный характер функционирования такой непараметрической системы адаптации.

Рассмотрим схематично процесс обучения непараметрической системы адаптации при активном накоплении информации. Сначала когда система не

«обучена», т.е. «знание» об объекте или процессе мало, основная роль в адаптации принадлежит второму члену в (2.36) Δr , который приводит объект к требуемому состоянию. Но по мере приведения объекта в требуемое состояние, обучающие точки поступают в адаптивную систему – система обучается. Если цель изменилась, то адаптивная система опять приводит объект в требуемое состояние, а доминирующая роль при формировании r все еще принадлежит Δr и система продолжает обучаться.

После некоторого времени обучения оптимальное решающее правило $\hat{r}^{\text{опт}}$ восстанавливается с достаточной степенью точности статистикой $\hat{r}^{\text{опт}}(s + 1)$ и достигает цели благодаря «знанию» модели объекта или процесса. На этом этапе доминирующую роль при формировании значения $\hat{r}^{\text{опт}}(s + 1)$ уже играет значение $\hat{r}^{\text{опт}*}(s)$, а не поисковые шаги. Когда адаптивная система «обучена», т.е. модель объекта восстановлена с требуемой точностью, то необходимость в поисковых шагах отпадает. Процесс активного накопления информации и обучения заканчивается.

Интересным представляется рассмотреть процесс накопления информации, при котором в адаптивную систему поступила обучающая выборка и в последующие моменты времени в систему продолжают поступать обучающие точки, т.е. обучение носит комбинированный характер. В отличие от рассмотренного выше процесса накопления информации на начальном этапе обучения такая система является «более обучено», хотя исходной обучающей выборки недостаточно для построения качественной адаптивной системы. Этот случай интересен ввиду того, что на практике при разработке адаптивных систем для крупных промышленных объектов чаще всего имеет место именно такая ситуация. Поэтому построение адаптивной системы начинается не «с нуля», а уже с некоторой степени «обученности», и, следовательно, процесс накопления информации состоит в доучивании системы.

Формально задача состоит в оценивании на основе имеющейся выборки и поступающих в адаптивную систему наблюдений оптимального решающего правила:

$$\hat{r}(w) = M\{r/w(u)\}. \quad (2.38)$$

Оценка имеет следующий вид:

$$\hat{r}^{\text{опт}}(s+1) = \hat{r}^{\text{опт}*}(s) + \Delta r(s+1), \quad (2.39)$$

где

$$\hat{r}^{\text{опт}*}(s) = \frac{\left(\sum_{t=1}^{s^0} \hat{r}^{\text{опт}}(t) \Phi\left(\frac{w(u)-w(u(t))}{c_s}\right) + \sum_{t=s^0}^s \hat{r}^{\text{опт}}(t) \Phi\left(\frac{w(u)-w(u(t))}{c_s}\right)\right)}{\sum_{t=1}^s \Phi\left(\frac{w(u)-w(u(t))}{c_s}\right)}, \quad (2.40)$$

а $\Delta r(s+1)$ – как и выше, поисковые шаги, обеспечивающие активное накопление информации.

При комбинированном обучении информация накапливается уже в сравнительно «обученной» системе. Накопление информации может осуществляться по следующему схеме. Сначала имеем исходную обучающую выборку $(r(i), w(i), i = \overline{1, s^0})$.

1. Выстраивается алгоритм обучения на выборке в соответствии с (2.39), но в (2.40) отсутствует второй член в числителе.

2. Далее осуществляется k тактов приведения объекта к желаемому состоянию. Новые k раз наблюдаемые переменные не вводятся в обучающую систему.

3. Теперь имеется выборка $(r(i), w(i), i = \overline{1, s^0 + k})$. Из этой выборки генерируется рабочая выборка $(r^N(i), w^N(i), i = \overline{1, s(N)})$.

4. На основе рабочей выборки выстраивается оценка $\hat{r}^{\text{опт}*}$ равная

$$\hat{r}^{\text{опт}*}(s) = \frac{1}{s(N)c_N} \sum_{i=1}^{s(N)} W_i^N H\left(\frac{w(u)-w^N(u(i))}{c_N}\right). \quad (2.41)$$

5. Следующий этап обучения начинается с пункта 2, который сопровождается получением новых k точек.

2.2 Алгоритмы параметрической оптимизации моделей

Параметрическая идентификация – нахождение параметров уравнений математической модели с известной структурой. Методы параметрической идентификации предполагают необходимость выбора (определения) вида аппроксимирующей функции $f(x, \lambda)$ с точностью до вектора параметров λ , который отыскивается из условия минимума критерия качества аппроксимации.

Общую постановку задачи параметрической идентификации можно записать следующим образом.

Необходимо, по имеющейся выборке входных выходных переменных $V = \{\bar{x}_i, y_i\}$, $i = \overline{1, s}$ определить коэффициенты α принятой структуры модели объекта.

Если обозначить $R(\bar{\lambda})$ – критерий качества аппроксимации, то задачу параметрической идентификации можно записать в следующем виде [55]:

$$R(\bar{\lambda}) = M\{(y(\bar{x}) - \tilde{y}(\bar{x}, \bar{\lambda}))^2\} = M\{Q(\bar{x}, \bar{\lambda})\} \rightarrow \min_{\bar{\lambda}} \quad (2.42)$$

где $Q(x, \bar{\lambda})$ - некоторая выпуклая функция качества.

Существует несколько подходов к решению задачи параметрической идентификации, в частности, построение рекуррентных процедур следующего вида:

$$\bar{\lambda}_s^i = \bar{\lambda}_{s-1}^i - \gamma_s \nabla_{\bar{\lambda}^i} Q(\bar{x}_s, \bar{\lambda}_{s-1}^i) \quad (2.43)$$

где s - номер пары наблюдений в выборке, $s = \overline{1, N}$;

N - объем выборки;

$\bar{\lambda}_0^i$ - вектор начальных приближений коэффициентов модели, которые в случае отсутствия априорной информации выбирается произвольно;

$\nabla_{\alpha^i} Q(x_s, \bar{\lambda}_{s-1}^i)$ - градиент функции $Q(x_s, \bar{\lambda}_{s-1}^i)$ по параметру $\bar{\lambda}^i$;

γ_s - некоторое число, удовлетворяющее условиям Роббинса-Монро:

1. $\gamma_s > 0, \forall s$;
2. $\gamma_s \neq 0, \forall s$;
3. $\lim_{s \rightarrow \infty} \gamma_s = 0$;
4. $\sum_{s=1}^{\infty} \gamma_s$ - расходящийся числовой ряд;
5. $\sum_{s=1}^{\infty} \gamma_s^2$ - сходящийся числовой ряд.

Отметим, что $\bar{\lambda}^*$ - точное решение, т. е. такое, что $R(\bar{\lambda}^*) = \min_{\bar{\lambda}} R(\bar{\lambda})$ - существует, но оно в реальных задачах никогда неизвестно.

Для рекуррентной процедуры доказана теорема сходимости:

$$\lim_{s \rightarrow \infty} M\{(\bar{\lambda}_s - \bar{\lambda}^*)^2\} = 0. \quad (2.44)$$

Существуют несколько алгоритмов, позволяющих повысить эффективность решения задачи настройки параметров модели с помощью рекуррентной процедуры, описанной выше. Под более высокой эффективностью понимается нахождение параметров $\bar{\lambda}$ более близких к оптимальным, и более высокая скорость сходимости параметров $\bar{\lambda}$ к оптимальным параметрам.

Простым и эффективным алгоритмом такого рода является алгоритм Литвакова.

2.2.1 Алгоритм Литвакова

Алгоритм позволяет отыскать близкое к оптимальному значение вектора параметров $\lambda = (\lambda^1, \dots, \lambda^m)$ с помощью рекуррентной процедуры:

$$\lambda(i) = \lambda(i-1) - \gamma(i) \nabla_x Q(x(i), \lambda(i-1)), \quad (2.45)$$

при не оптимальном $\gamma(i)$.

Сущность его состоит в следующем:

Положим $\lambda(0) = \lambda_0$ и $\gamma(i) = ai^{-1}$, где a – некоторая постоянная, осуществляется итеративный процесс вычислений по формуле (2.45). на s -ом шаге находится $\lambda(s)$, которое принимается в качестве нового начального условия и процесс вычислений продолжается по той же самой выборке $V = \{x_i, y_i\}$, $i = \overline{1, s}$.

В результате получаем оценку $\lambda(2s)$. Продолжая этот процесс k раз, найдем оценку $\lambda(k, s)$. Результат Литвакова состоит в том, что оценка $\lambda(k, s)$ для достаточно больших k (точнее $k \rightarrow \infty$) приближается к $\lambda^{opt}(s)$.

1. Общая схема алгоритма выглядит следующим образом:
2. Выбираем некоторое начальное приближение $\vec{\lambda}_0$.
3. За t итераций получаем некоторую оценку $\vec{\lambda}_t$, где число t равно числу наблюдений в выборке.
4. Снова запускаем рекуррентную процедуру, но за начальное приближение $\vec{\lambda}_0$ берем полученное на предыдущем шаге $\vec{\lambda}_t$, за t шагов получаем оценку $\vec{\lambda}_{2t}$.
5. Проделываем M таких циклов.

Обычно на практике число $M = 3 \div 5$.

2.2.2 Алгоритм Кестена

Известно, что скорость сходимости рекуррентных вероятностных алгоритмов рассматриваемого типа при $\gamma(i) = ai^{-1}$ определяется степенным знаком – это следствие влияние помех. Если бы помехи отсутствовали, то следо-

вало бы $\gamma(i) = const$, скорость сходимости при этом возрастает и определяется показательным законом.

Сущность алгоритма Кестена состоит в том, что вдали от $\lambda^* = \lambda^{opt}$ роль помех при измерениях $\{x_i, y_i\}$, $i = \overline{1, s}$ мала и разность $(\lambda(i) - \lambda(i-1))$ будет иметь постоянный знак, а вблизи λ^* знак $(\lambda(i) - \lambda(i-1))$ уже существенно зависит от помех и будет меняться. Предполагается, что начальное приближение взято сравнительно далеко от точки минимума $\bar{\lambda}^*$. До тех пор, пока градиент не меняет знак (движемся в нужном направлении) не меняем $\gamma_s^{\lambda_i}$, а когда знак градиента сменится, т.е. произойдет перескок через точку минимума, меняем $\gamma_s^{\lambda_i}$. И вновь оставляем неизменной, до тех пор, пока опять не произойдет перескок.

Чтобы определить разность $(\lambda(i) - \lambda(i-1))$ необходимо, по крайней мере, два измерения. Поэтому $\gamma(0)$ и $\gamma(1)$ выбираются произвольно (обычно равными единице). Дальнейшее определение $\gamma(i)$ подчинено правилу:

$$\gamma(i) = \gamma(N(i)), \quad (2.46)$$

где $N(i)$ целочисленная функция, определяемая выражением

$$N(i) = 2 + i - \sum_{m=1}^i \text{sgn}\{(\lambda(i-1) - \lambda(i-2))(\lambda(i-2) - \lambda(i-3))\}, \quad (2.47)$$

$$\text{где } \text{sgn } z = \begin{cases} 1, & z \geq 0 \\ 0, & z < 0 \end{cases}, \quad z \text{ — произвольный аргумент.}$$

Этот алгоритм позволяет повысить скорость отыскания точки минимума, т.к. скорость движения к нему не уменьшается постоянно с возрастанием номера итерации.

Алгоритм Литвакова и алгоритм Кестена относятся к одношаговым рекуррентным алгоритмам. Возможно совместное использование этих двух алгоритмов.

2.2.3 Правило остановки

При практическом использовании алгоритмов (2.45), естественно возникает вопрос: при каком числе шагов можно считать, что мы с достаточной степенью точности определим оптимальное значение вектора λ^* . Для достаточно надежного определения $i = i^0$ необходимо тем или иным способом «сгладить» последовательность $\lambda(i)$. Одна из таких возможностей состоит в использовании скользящего среднего

$$N_z(i) = Z^{-1} \sum_{k=i}^{i+Z} \lambda(k) . \quad (2.48)$$

Если, начиная с некоторого k^0 , для всех $k \geq k^0$ имеет место неравенство:

$$\|N_z(k - Z) - N_z((k + 1) - Z)\| < \varepsilon , \quad (2.49)$$

где $\varepsilon > 0$ – достаточно малая величина, то величина $i^0 = k^0 Z$ определяет тот момент времени, когда можно считать, что:

$$M\{\lambda(i^0)\} \approx \lambda^* . \quad (2.50)$$

Сглаживание $\lambda(i)$ можно осуществлять и иным путем, а именно:

$$\lambda(i) = \lambda(i - 1) - \gamma(i) \nabla_A Q(Ax(i), \lambda(i - 1)), \quad (2.51)$$

где A – оператор сглаживания, например:

$$Ax(i) = Z^{-1} \sum_{m=i}^{i+Z} x(m) . \quad (2.52)$$

Здесь сглаживание $\lambda(i)$ осуществляется за счет предварительной обработки наблюдений.

2.3 Эволюционный генетический алгоритм оптимизации параметров моделей технологических систем нефтегазового комплекса

Генетические алгоритмы являются мощным средством решения оптимизационных задач. Генетические алгоритмы доказали свою состоятельность при решении многих трудных задач поиска и оптимизации и, особенно, в практических приложениях, где математические модели имеют сложную структуру и применение классических методов невозможно или чрезвычайно трудоемко [56].

2.3.1 Оптимизируемые параметры моделей технологических систем нефтегазового комплекса

В рамках рассматриваемой работы генетический алгоритм применялся для оптимизации параметров моделей, построенных с помощью описанных в пп. 2.1.1-2.1.5 методов:

1. Для моделей, построенных методом многомерных адаптивных регрессионных сплайнов, выполнялась оптимизация пороговых значений базисных функций.
2. Для моделей, построенных с помощью регрессионных деревьев, выполнялась оптимизация параметров разбиения в узлах дерева.
3. Для моделей, построенных с помощью метода генетического программирования, выполнялась оптимизация числовых параметров – констант в формуле регрессионной модели.
4. Для непараметрических регрессионных моделей выполнялась настройка многомерного параметра размытости.

2.3.2 Основные операторы генетического алгоритма

В основу данного метода оптимизации положена идея имитации эволюционных процессов, происходящих в живой природе среди особей какой-

либо популяции [56]. Особь (индивид) представляет собой решение, закодированное определенным образом, например в бинарную строку. Совокупность решений в конкретный момент времени составляет популяцию. Индивиды текущей популяции конкурируют друг с другом за передачу своей генетической информации (создание потомков) в следующую популяцию. К индивидам, отобранным из текущей популяции с помощью оператора селекции, последовательно применяются операторы рекомбинации и мутации. Полученные новые решения (потомки) с заданной вероятностью заменяют решения исходной популяции. Каждый индивид в генетическом алгоритме характеризуется некоторым числом (*пригодностью*), обозначающим меру его адаптации к окружающей среде.

Функция пригодности

Пригодность индивида (fitness) – это некоторая количественная оценка качества решения поставленной задачи. Функция пригодности может быть спроектирована с учетом особенностей решаемой задачи (что делает генетический алгоритм довольно гибким и универсальным). Обычно функция пригодности принимает положительные значения, и значение пригодности максимизируют.

В общем случае при решении задач безусловной оптимизации в качестве значения функции пригодности может выступать значение оптимизируемого функционала.

При решении задачи обучения параметрической оптимизации регрессионных моделей в качестве функции пригодности обычно используют величину, обратно пропорциональную ошибке синтезируемой модели на тестовой выборке:

$$fitness_i = \frac{1}{1+Error_i}, i = \overline{1, n}, \quad (2.53)$$

где i – номер индивида в популяции;

n – размер популяции;

$Error_i$ – ошибка для регрессионной модели с набором параметров, соответствующим -му индивиду в текущей популяции.

Представление решений

Решения в генетическом алгоритме представляются в виде хромосом (генотипов). Генотип – строка конечной длины, состоящая из генов, представленных символами некоторого алфавита.

В генетическом алгоритме существует строгое различие между фенотипом (решением, выраженным в терминах поставленной задачи) и генотипом (хромосомой, представлением решения). Генетический алгоритм работает с генотипом, а фенотип служит для определения пригодности индивида (оценки качества решения поставленной задачи), поэтому для работы алгоритма необходимо определить некоторую функцию кодирования ($e: D \rightarrow S$, где D - пространство поиска, S - пространство представлений решений) и функцию декодирования ($e^{-1}: S \rightarrow D$) [57].

Стандартным для генетических алгоритмов является представление решений в виде бинарной строки [58]. В настоящее время наиболее часто используются стандартное бинарное кодирование и бинарные коды Грея.

При решении задачи настройки весовых коэффициентов нейронной сети использование бинарного кодирования заключается в представлении каждого весового коэффициента некоторой последовательностью бит конечной длины. В целом, генотип (хромосома) представляет собой конкатенацию битовых последовательностей, кодирующих все весовые коэффициенты обучаемой сети.

Точность представления переменных задачи в генетических алгоритмах определяется числом бит отводимых на кодирование каждой переменной, при этом на предварительном этапе работы с алгоритмом должен быть определен некоторый компромисс между точностью представления и длиной хромосомы, представляющей решение в целом.

В задаче обучения нейронных сетей, в случае использования слишком малого числа бит для кодирования решения (что соответствует использованию слишком крупного шага решетки дискретизации), алгоритм обучения может оказаться неспособным аппроксимировать с приемлемой точностью некоторые вещественные значения весовых коэффициентов, что может явиться решающим фактором в падении эффективности обучающего процесса. С другой стороны слишком мелкий шаг решетки дискретизации приведет к значительному возрастанию длины хромосом (особенно в случае обучения сетей большого размера), что также может повлечь значительное снижение эффективности эволюционного поиска.

Преимуществом бинарного представления является простота интерпретации и возможность применения хорошо разработанных и изученных классических операторов генетического алгоритма.

Общая схема генетического алгоритма

В общем виде работу генетического алгоритма можно представить следующим образом:

1. Инициализируется случайным образом популяция решений.
 2. С помощью оператора *селекции* выбирается часть популяции (родителей) для порождения потомков.
 3. Применяется оператор *скрещивания*.
 4. Новые решения (потомки) подвергаются *мутации*.
 5. Формируется новая популяция: выбираются решения из родителей и потомков.
 6. Шаги 2 – 5 повторяются пока не выполнится условие остановки.
- Блок схема генетического алгоритма представлена на рисунке 2.5:

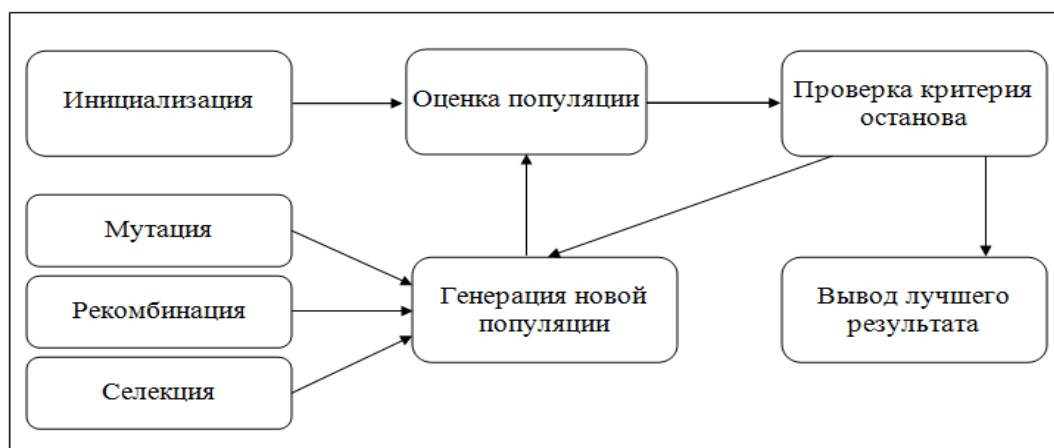


Рисунок 2.5 – Блок-схема генетического алгоритма

Инициализация

На этапе инициализации задаются параметры алгоритма: длина хромосомы, размер популяции и число точек поиска, а также типы и вероятности применения основных генетических операторов (скрещивания, мутации и селекции), генерируется начальное поколение.

В случае отсутствия априорных сведений о пространстве поиска и использовании бинарного кодирования начальное поколение в генетическом алгоритме формируется следующим образом: гены в хромосоме, кодирующей решение, случайным образом с равной вероятностью заполняются нулями или единицами.

Операторы генетического алгоритма

Основными операторами генетического алгоритма являются операторы селекции, скрещивания (рекомбинации) и мутации.

Селекция

Оператор селекции - оператор, с помощью которого индивиды выбираются для порождения потомков. Существует несколько основных типов оператора селекции (пропорциональная, ранговая, турнирная, элитарная), а выбор в пользу конкретного оператора зачастую продиктован спецификой решаемой задачи. Однако любой вид оператора селекции должен удовлетворять следующему требованию – наиболее приспособленные особи из текущего поколения должны выбираться с большей вероятностью для сохранения

своих генов в последующем поколении (таким образом осуществляется так называемое селективное *давление*). Это позволяет сконцентрировать поиск в наиболее перспективных (с точки зрения решаемой задачи) областях поискового пространства.

Рекомбинация

В генетическом алгоритме с помощью оператора рекомбинации признаки родителей – индивидов текущего поколения – передаются потомкам (индивидам следующего поколения). Это достигается благодаря тому, что потомки по заданному правилу формируются из частей хромосом отобранных индивидов (родителей), то есть оператор рекомбинации является оператором поиска новых решений на основе решений, отобранных селекцией.

Существует несколько основных схем рекомбинации – одноточечная, двухточечная, равномерная рекомбинация, рекомбинация более чем двух родителей.

Мутация

Оператор мутации – это оператор поиска, заключающийся в случайном изменении одного или несколько генов индивида. Применение оператора мутации необходимо для поддержания разнообразия в популяции и восстановления утерянной генетической информации. Таким образом, мутация позволяет более полно обследовать пространство поиска.

В случае использования двоичного кодирования решений применение оператора мутации может быть проиллюстрировано следующим образом:




Рисунок 2.6 – Пример мутации в генетическом алгоритме

Существует эмпирическое правило, позволяющее удачно выбрать вероятность мутации $p_m = \frac{1}{s}$, где s – число генов хромосоме. Это правило позволяет произвести следующую классификацию мутации:

- Слабая: $p_m < \frac{1}{3s}$.
- Средняя: $p_m = \frac{1}{s}$.
- Сильная: $p_m > \frac{3}{s}$.

Кроме того, некоторые исследователи рекомендуют выбирать вероятность мутации таким образом, чтобы она попадала в интервал $p_m \in [0.001; 0.01]$.

Исследование алгоритмов параметрической оптимизации моделей и генетического алгоритма оптимизации параметров моделей, используемых для управления технологическими объектами нефтепереработки (на примере ректификационной колонны), представлено в разделе 3.2.

Выводы

В данной главе рассмотрены методы построения регрессионных моделей, используемые в рамках диссертационного исследования для построения моделей, которые могут быть использованы в качестве алгоритмического ядра автоматизированных систем управления технологическими объектами нефтегазового комплекса. Приведены основные характеристики и схемы построения «быстрых» регрессионных моделей, изложены основы проектирования моделей, определены параметры моделей, которые должны быть идентифицированы и настроены в рамках комплексного оптимизационного подхода.

Для оптимизации параметров моделей предлагается использовать специализированные алгоритмы параметрической оптимизации – алгоритм Литвакова и алгоритм Кестена. В качестве альтернативы рассмотрен эволюцион-

ный алгоритм оптимизации – генетический алгоритм. Данный алгоритм зарекомендовал себя как эффективное средство решения сложных задач многомерной оптимизации и теоретически способен позволить существенно повысить точно настройки параметров моделей технологических систем с различной структурой.

3 ИССЛЕДОВАНИЕ ЭФФЕКТИВНОСТИ МЕТОДОВ ПОСТРОЕНИЯ И ОПТИМИЗАЦИИ МОДЕЛЕЙ ТЕХНОЛОГИЧЕСКИХ СИСТЕМ

Апробация методов с целью оценки их эффективности является неотъемлемой частью исследования методов моделирования и оптимизации технологических процессов. Для оценки эффективности таких методов должен быть рассмотрен ряд задач, решение которых позволит значимо утверждать возможности их использования для эффективного построения моделей производственных и технологических систем нефтегазового комплекса и их параметрической оптимизации. К числу таких задач, которые должны быть решены в рамках данной части научного исследования относятся:

1. Выбор критерия или нескольких критериев качества регрессионных моделей, синтезированных с помощью исследуемого метода. В каждом разделе данной главы данный вопрос освещается с учетом используемой для синтеза моделей программной системой, каждая из которых позволяет вычислять определенные оценки качества модели. В рамках проводимых исследований делался упор на получение максимально широкого набора значений, позволяющих численно оценить качество регрессионной модели (а следовательно и эффективность подхода, используемого для ее построения). В качестве таких критериев использовались оценки математического ожидания абсолютных и квадратичных ошибок моделирования на тестовых выборках. Для проверки статистической устойчивости и значимости получаемых результатов применялся метод ANOVA, который учитывает дисперсию получаемых наблюдений ошибок моделирования и позволяет проверить гипотезу о существенности различий получаемых оценок математического ожидания. Очевидным видится, что эффективность метода построения моделей (в том числе и для технологических и производственных систем нефтегазового комплекса) находится в прямой зависимости от точности и адекватности моделей, которые данный метод позволяет получить. Следовательно, метод считается более эффективным (с учетом незначительности времени на по-

строение модели и расчет значений по ней – данные операции на современном настольном компьютере для рассматриваемых в работе реальных производственных систем реализуются в течение нескольких секунд), если обеспечивает значимо меньшее значение оценки математического ожидания ошибки моделирования.

2. Определение схемы исследования, позволяющей получить наиболее корректные результаты с точки зрения оценки эффективности рассматриваемых подходов. Очевидным видится необходимость проведения статистических исследований, сопряженных с многократной оценкой эффективности методов моделирования по выбранным критериям и набором выборок достаточных для получения статистически значимых оценок. Широко распространенный базовый подход предполагает многократное разбиение выборок, используемых для построения моделей на несколько частей, включая многократный случайный выбор элементов, входящих в каждую подвыборку. Такой подход широко используется в научных работах, посвященных синтезу регрессионных и классификационных моделей, его эффективность подтверждена значительным количеством практико-ориентированных работ в данной области.

3. Определение параметров исследуемых методов и реализующих их алгоритмов – рассматриваемые в работе методы построения моделей технологических систем нефтегазового комплекса и методы оптимизации таких моделей обладают настраиваемыми параметрами, от выбора которых существенно зависят получаемые значения оценки эффективности. В этой связи в рамках проводимых в диссертации исследований предполагается осуществление предварительного подбора «наилучших в среднем» параметров на наборе тестовых задач, либо определение таких параметров в результате предварительных исследований на рассматриваемой задаче.

4. Выбор и формализация задачи, используемой для оценки эффективности методов построения и оптимизации моделей, включая определение и описание переменных задачи (входных и выходных переменных).

3.1 Исследование эффективности методов моделирования на тестовых задачах

В качестве главного критерия эффективности использовались *оценка математического ожидания* и *оценка дисперсии ошибки моделирования*, рассчитанные по данным, полученным в ходе 50 независимых запусков алгоритмов. Для расчета ошибки аппроксимации в каждом запуске использовалась следующая формула:

$$Error = \frac{100\%}{s(y^{\max} - y^{\min})} \sum_{i=1}^s |o_i - y_i|. \quad (3.1)$$

где i — номер записи в выборке;

o_i - выход коллектива нейронных сетей;

y_i - значение выходной переменной в выборке;

y^{\max} и y^{\min} - максимальное и минимальное значение выходной переменной,

s - число элементов в выборке.

Для всех методов, с целью получения корректных результатов численных экспериментов, использовалось одинаковое количество вычислительных ресурсов.

Для исследования значимости различий в эффективности используемых подходов были использованы методы ANOVA. Было проведено попарное сравнение исследуемых методов для выявления статистической значимости в различимости получаемых в ходе тестирования результатов при уровне значимости $\alpha = 0,05$.

Тестовые задачи

Примеры задач аппроксимации функций, использовавшихся в сравнительных исследованиях, приведены в таблице 3.1.

Таблица 3.1 – Тестовые задачи моделирования функций

№ задачи	Моделируемая функция	Диапазон входных переменных	Объем выборки
1	$y = \sin x$	$x \in [-4, 3]$	150
2	$y = x_1^2 \sin x_1 + x_2^2 \sin x_2$	$x_i \in [-4, 3]$	150
3	$y = \frac{x_1 \cdot x_2}{x_3^2}$	$x_i \in [1, 20]$	200
4	Rosenbrock: $y = 100(x_2 - x_1^2)^2 - (1 - x_1)^2$	$x_i \in [-2, 3]$	200
5	2-d Mexican Hat: $y = \frac{\sin x }{ x }$	$x \in [-2\pi, 2\pi]$	500
6	3-d Mexican-Hat: $y = \frac{\sin\sqrt{x_1^2 + x_2^2}}{\sqrt{x_1^2 + x_2^2}}$	$x_i \in [-4\pi, 4\pi]$	1000
7	Friedman 1: $y = 10\sin(\pi x_1 x_2) + 20(x_3 - 0.5)^2 + 10x^4 + 5x^5$	$x_i \in [0, 1]$	1000
8	Friedman 2: $y = \sqrt{x_1^2 + \left(x_2 x_2 - \frac{1}{x_2 x_4}\right)^2}$	$x_1 \in [0, 100]$ $x_2 \in [40\pi, 560\pi]$ $x_3 \in [0, 1]$ $x_4 \in [1, 11]$	1000
9	Gabor: $y = \frac{\pi}{2} \exp[-2(x_1^2 + x_2^2)] \cos[2\pi(x_1 + x_2)]$	$x_i \in [0, 1]$	1000
10	Multi: $y = 0.79 + 1.27x_1x_2 + 1.56x_1x_2 + 3.42x_2x_5 + 2.06x_3x_4x_5$	$x_i \in [0, 1]$	1000

Результаты

Фрагмент результатов численных исследований эффективности разработанного метода и других методов формирования общего решения в коллективах нейронных сетей, описанных выше, приведены в таблице 3.2.

Таблица 3.2 – Результаты решения тестовых задач

Задача	Оценка математического ожидания ошибки моделирования, %			
	GASEN	GA-based1	GA-based2	Предлагаемый подход
1	1,444	1,335	1,302	0,855
2	3,479	3,486	3,482	3,037
3	1,679	1,651	1,639	1,389
4	6,192	6,147	6,100	5,036
5	1,917	1,833	1,747	1,368
6	4,916	4,745	4,528	4,568
7	6,095	6,083	6,152	5,218
8	3,821	3,824	3,818	2,845
9	3,168	3,305	3,124	2,272
10	3,163	3,157	3,121	2,979

3.2 Моделирование вакуумных установок

Вопросы моделирования сложных ректификационных колонн для разделения нефтяных смесей достаточно подробно изложены в литературе [59,60]. Модели подобного типа называются неформальными, часто их называют также физико-химическими, термодинамическими. В большинстве случаев моделируются статические режимы колонн, хотя известен ряд работ, посвященных моделированию переходных режимов. Модели данного класса не удовлетворяют требованиям, предъявляемым к моделям для целей опера-

тивного управления, так называемым «быстрым» моделям, по трем главным и принципиальным причинам:

- модели не позволяют прогнозировать значения параметров технологических установок по измеряемым технологическим параметрам;
- время, необходимое для проведения расчетов даже на современных компьютерах;
- объем исходной информации и ее состав не могут быть подготовлены оперативно; в частности, для расчетов требуется знать состав исходного сырья.

Построение моделей для определения параметров боковых отборов вакуумных колонных установок и получение численных оценок соответствующих параметров позволило бы определить параметры необходимые для рационального выбора значений управляющих параметров для таких технологических систем. Существующие методы и модели, как уже было сказано выше требуют использования значительного объема информации о косвенных параметрах и накопления базы данных справочного назначения.

Кроме того, с учетом использования на автоматизированных рабочих местах микроконтроллеров и ЭВМ, производительность которых значительно ограничена, а высокопроизводительные ЭВМ в соответствующих условиях эксплуатировать нецелесообразно. Обоснованным видится применение упрощенных, «быстрых» подходов к модельному расчету этих показателей применительно к продуктам разделения нефтяных смесей в вакуумных колоннах. Очевидно, что для эффективного расчета значений параметров, необходимых для управления технологическими процессами в рамках производственных систем нефтепереработки, требуется построения моделей удовлетворяющих критериям простоты (для расчета достаточно производительности стандартной настольной ЭВМ или вычислительных мощностей современных микроконтроллеров) и точности воспроизведения моделируемых параметров. Для построения таких моделей в диссертации предложено использовать регрессионные методы, описанные в главе 2. Актуальной задачей ви-

дится определение методов, обеспечивающих наибольшую точность прогнозирования параметров моделей, необходимых для оценки состояния технологических процессов и оценки управляющих воздействий для соответствующих технологических установок.

Анализ полученных по этому пункту результатов позволил сделать следующие выводы:

- чувствительность температур на тарелках по высоте колонны к изменению параметров технологического режима колеблется на два порядка;
- характер изменения температур на отдельных тарелках по отношению к знакопеременному изменению технологических параметров резко ассиметричен, что объясняется совокупным действием взаимозависимых технологических параметров;
- выбор наиболее информативных параметров (входных координат) для уравнений регрессии, связывающих значения ПК с технологическими параметрами в сложных ректификационных колоннах, должен производиться не только по максимальной чувствительности, но и с учетом однозначности, по возможности, симметричности зависимостей между параметрами.

При проведении корреляционного анализа ставились две основные задачи:

1. Выделения множества информативных параметров для построения быстрой модели вычисления; характерных точек ИТК;
2. Определение структуры уравнений регрессий, связывающих значения характерных точек ИТК с информативными технологическими параметрами.

В таблице приложения 2 приведены результаты корреляционного анализа для колонны для К-5 установки АВТм-9. В частности, исследовались зависимости характерных точек ИТК от нелинейных и смешанных факторов, от величин, характеризующих внутренние паровые и жидкостные потоки в колоннах. Расчеты проводились известными методами.

Из приведенных данных видно, что достаточно близкие к единице значения характерных точек ИТК коррелированы с температурами на тарелках отбора боковых потоков. При этом введение нелинейных и смешанных факторов несущественно изменяют коэффициенты корреляции и корреляционных отношений. В ряде случаев значения коэффициентов корреляции и корреляционных отношений одновременно близки по модулю к единице, а в других - различаются достаточно существенно. Последнее указывает на то, что между рассматриваемыми факторами существует тесная, но не линейная связь.

Сделанный анализ позволил сформировать подмножество параметров, которые являются наиболее информативными для целей расчета ПК продуктов разделения. К ним относятся:

1. Температуры на отдельных тарелках по высоте колонны, в т.ч. температуры на тарелках отбора, при заданном составе сырья и фиксированном давлении P в колонне;
2. Относительные суммы отборов продуктов разделения при фиксированных значениях парового потока в колонне.
3. Значения температур t_i , $i = \overline{0,5}$; где $i = 0$ соответствует значению температуры верха колонны, $i = 5$ соответствует значению температуры низа колонны; $i = \overline{1,4}$ соответствуют значениям температур на тарелках отбора;
3. P_0 значение давления вверху колонны;
4. Значения отборов боковых потоков D_i , $i = \overline{1,4}$; и сверху колонны D_0 , величина парового потока в колонне G . Обычно величины D_0 , G не измеряются, поэтому их величины предлагается рассчитывать по известным соотношениям.

Связь выделенных подмножеств параметров с характерными точками ИТК имеет ясный физический смысл: первое имеет в основе уравнения фазового равновесия, а второе - уравнения материального баланса.

Вторая часть задачи построения «быстрой» модели, т.е. определение коэффициентов уравнений регрессии, решается рассмотренными в диссертации методами параметрической оптимизации регрессионных моделей.

3.3 Результаты решения задачи моделирования технологической установки колонны к-5

Сокращение пространства признаков. Определение значимых факторов

Как уже было сказано выше, перед построением модели необходимо определить входные переменные, для которых статистически значимо можно утверждать о существенном их влиянии на моделируемые технологические параметры. В связи с этим перед непосредственным построением модели с помощью методов статистического анализа для каждого моделируемого технологического параметра из всего набора входных параметров выбирались значимые факторы – переменные, оказывающие наиболее существенное влияние на моделируемый параметр. Статистический анализ выполнялся с помощью прикладного пакета прикладного статистического анализа Statsoft Statistica.

Полученные в рамках данного раздела диссертации результаты представляют собой существенный научный результат, так как в открытых источниках подобных результатов статистического анализа для рассматриваемых технологических установок обнаружить не удалось. В работах, посвященных этой тематике внимания данному шагу, имеющему существенное значение с точки зрения построения и оптимизации моделей рассматриваемых технологических установок не уделялось.

Результаты определения значимых факторов – входных переменных приведены для каждого моделируемого параметра далее. Результаты получены при уровне доверительной вероятности 0,9.

Построение регрессионных моделей

Для построения моделей расчета технологических параметров рассматриваемой технологической установки использовались специализированные программные средства.

- Для синтеза моделей на основе искусственных нейронных сетей, регрессионных деревьев и многомерных регрессионных сплайнов применялся пакет прикладного статистического анализа Statsoft Statistica.
- Для синтеза моделей с помощью методов непараметрической оценки регрессии и генетического программирования использовалась программная система IT-Pegasus.

Параметрическая оптимизация моделей

Для параметрической оптимизации моделей построенных различными методами синтеза регрессионных моделей использовался описанный выше эволюционный генетический алгоритм и рассмотренные в главе 2 алгоритмы параметрической оптимизации Литвакова и Кестена. Для определения набора параметров оптимизации рассматривалась каждая синтезированная модель, и определялись численные параметры, настройка которых возможна в рамках построенной структуры модели.

Так как рассматриваемый в качестве основного алгоритма параметрической оптимизации моделей управления генетический алгоритм требует представления решений в виде двоичных строк выполнялась дискретизация параметров моделей, при этом шаг дискретизации выбирался не превышающим 0,001. Интервал варьирования переменных определялся индивидуально для каждой модели и выбирался исходя из соображений полного перекрытия исходных значений параметров, сгенерированных непосредственного алгоритмом идентификации.

В качестве критерия оптимизации использовался критерий, определяемый формулой 3.2.

Параметры используемых алгоритмов оптимизации были определены в ходе предварительного тестирования на наборе тестовых функций, в который входит 25 тестовых задач, наиболее часто используемых в исследованиях по данному направлению. Параметры оказывающие влияние на продолжительность подстройки параметров были выбран следующие: общее число шагов поиска не более 100, число точек поиска решения на каждом шаге 100.

Критерии оценки моделей

1. В качестве главного критерия эффективности использовались *оценка математического ожидания* и *оценка дисперсии ошибки моделирования*, рассчитанные по данным, полученным в ходе 50 независимых запусков алгоритмов. Для расчета ошибки аппроксимации в каждом запуске использовалась следующая формула:

$$Error = \frac{100\%}{s(y^{\max} - y^{\min})} \sum_{i=1}^s |o_i - y_i|. \quad (3.2)$$

Для оценки показателей использовался пакет прикладного статистического анализа Statsoft Statistica.

Ввиду необходимости обезличивания результатов исследований с учетом обеспечения режима конфиденциальности информации, используемой в качестве исходных данных для построения регрессионных моделей, соответствующие параметры моделируемой технологической установки были обезличены и в таблицах и на графика представлены как «Переменная i » или ввиду использования англоязычных версий программного обеспечения «Var i », где $i = \overline{19,30}$.

Переменная 19

Результаты отбора входных переменных приведены в таблице 3.3.

Таблица 3.3 – Результаты отбора переменных для моделирования параметра 19

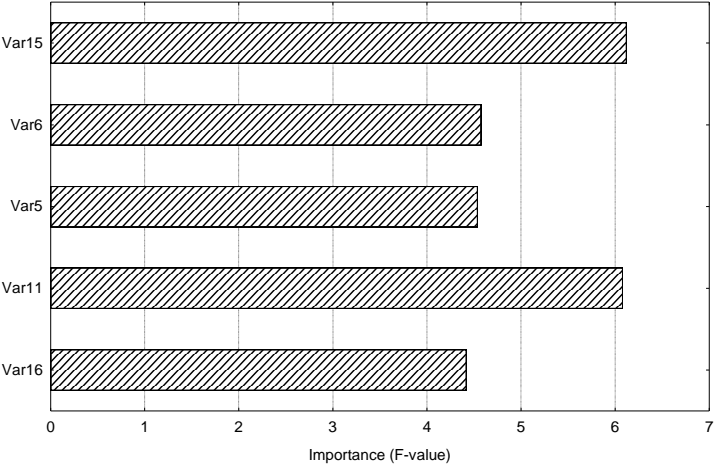
Значения критериев отбора переменных			Графическая интерпретация результата	
	F-value	p-value	<p>Importance plot Dependent variable: Var19</p>  <p>Рисунок 3.1 – Гистограмма важности входных параметров для моделирования параметра 19</p>	
Var15	6,122894	0,009938		
Var6	4,574590	0,012939		
Var5	4,540106	0,017425		
Var11	6,082549	0,023924		
Var16	4,419795	0,028470		

Таблица 3.4 – Оценки точности построения регрессионной модели для параметра 19

Метод	Критерии оценки точности построения регрессионной модели без оптимизации параметров / с оптимизацией параметров	
	Средняя относительная ошибка моделирования, %	
Искусственные нейронные сети	14,4	5,5
Многомерные регрессионные сплайны	5,9	3,9
Деревья решений	18,1	11,1
Генетическое программирование	14,8	8,7
Непараметрическая регрессия	11,3	8,9

Переменная 20

Результаты отбора входных переменных приведены в таблице 3.5.

Таблица 3.5 – Результаты отбора переменных для моделирования параметра 20

Значения критериев отбора переменных			Графическая интерпретация результата
	F-value	p-value	 <p>Рисунок 3.2 – Гистограмма важности входных параметров для моделирования переменной 20</p>
Var15	40,43291	0,000000	
Var11	16,62483	0,000100	
Var16	10,28435	0,000327	
Var5	4,56011	0,010525	
Var18	4,53776	0,011420	
Var17	4,12469	0,016374	
Var6	3,51148	0,028886	

Таблица 3.6 – Оценки точности построения регрессионной модели для параметра 20

Метод	Критерии оценки точности построения регрессионной модели без оптимизации параметров / с оптимизацией параметров	
	Средняя относительная ошибка моделирования, %	
Искусственные нейронные сети	12,3	4,4
Многомерные регрессионные сплайны	5,5	5,4
Деревья решений	14,1	7,8
Генетическое программирование	15,3	9,1
Непараметрическая регрессия	15,2	7,5

Переменная 21

Результаты отбора входных переменных приведены в таблице 3.7.

Таблица 3.7 – Результаты отбора переменных для моделирования параметра 21

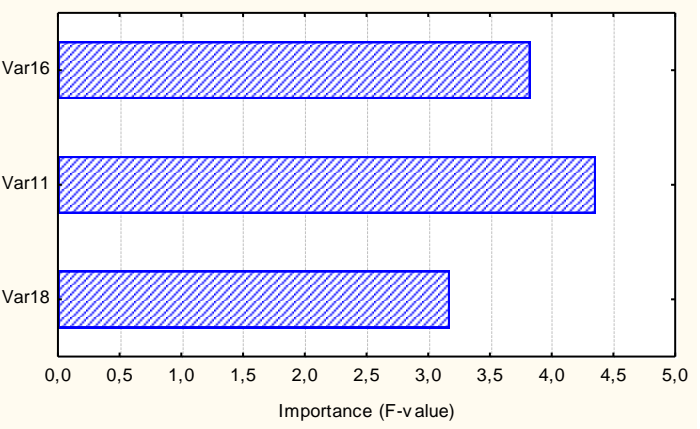
Значения критериев отбора переменных			Графическая интерпретация результата
	F-value	p-value	<p>Importance plot Dependent variable: Var21</p>  <p>Рисунок 3.3 – Гистограмма важности входных параметров для моделирования переменной 21</p>
Var16	3,828213	0,024474	
Var11	4,357595	0,029662	
Var18	3,175000	0,040155	

Таблица 3.8 – Оценки точности построения регрессионной модели для параметра 21

Метод	Критерии оценки точности построения регрессионной модели без оптимизации параметров / с оптимизацией параметров	
	Средняя относительная ошибка моделирования, %	
Искусственные нейронные сети	10,3	5,2
Многомерные регрессионные сплайны	7,3	5,1
Деревья решений	15,6	7,5
Генетическое программирование	16,7	8,9
Непараметрическая регрессия	12,1	7,2

Переменная 22

Результаты отбора входных переменных приведены в таблице 3.9.

Таблица 3.9 – Результаты отбора переменных для моделирования параметра 22

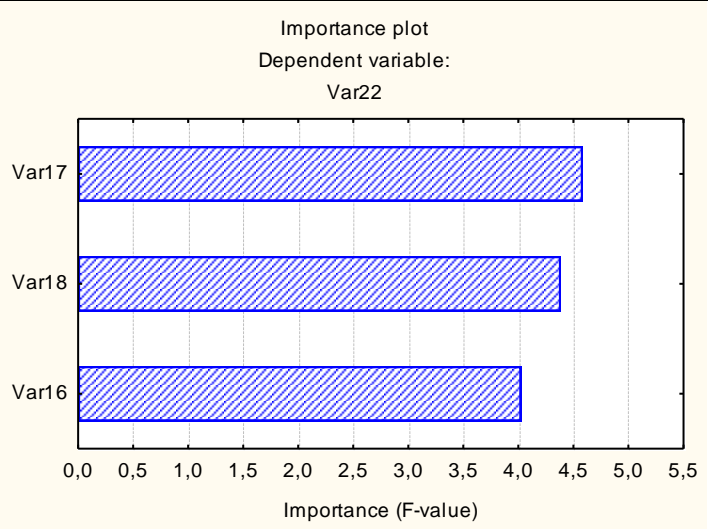
Значения критериев отбора переменных			Графическая интерпретация результата
	F-value	p-value	<p>Importance plot Dependent variable: Var22</p>  <p>Рисунок 3.4 – Гистограмма важности входных параметров для моделирования переменной 22</p>
Var17	4,586302	0,010959	
Var18	4,386326	0,013007	
Var16	4,026837	0,020556	

Таблица 3.10 – Оценки точности построения регрессионной модели для параметра 22

Метод	Критерии оценки точности построения регрессионной модели без оптимизации параметров / с оптимизацией параметров	
	Средняя относительная ошибка моделирования, %	
Искусственные нейронные сети	10,5	5,1
Многомерные регрессионные сплайны	8,2	4,9
Деревья решений	19,4	8,7
Генетическое программирование	14,1	8,6
Непараметрическая регрессия	11,2	7,1

Переменная 23

Результаты отбора входных переменных приведены в таблице 3.11.

Таблица 3.11 – Результаты отбора переменных для моделирования параметра 23

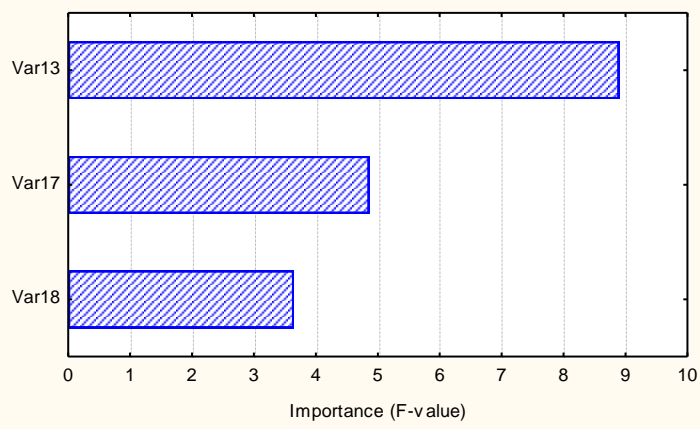
Значения критериев отбора переменных			Графическая интерпретация результата
	F-value	p-value	<p>Importance plot Dependent variable: Var23</p>  <p>Рисунок 3.5 – Гистограмма важности входных параметров для моделирования переменной 23</p>
Var13	8,897204	0,002270	
Var17	4,862915	0,008699	
Var18	3,647505	0,025378	

Таблица 3.12 – Оценки точности построения регрессионной модели для параметра 23

Метод	Критерии оценки точности построения регрессионной модели без оптимизации параметров / с оптимизацией параметров	
	Средняя относительная ошибка моделирования, %	
Искусственные нейронные сети	12,5	4,4
Многомерные регрессионные сплайны	9,1	2,7
Деревья решений	17,2	9,1
Генетическое программирование	17,1	10,0
Непараметрическая регрессия	13,7	6,6

Переменная 24

Результаты отбора входных переменных приведены в таблице 3.13.

Таблица 3.13 – Результаты отбора переменных для моделирования параметра 24

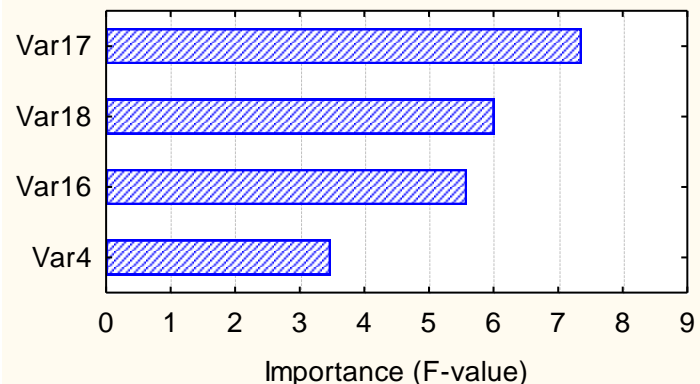
Значения критериев отбора переменных			Графическая интерпретация результата	
	F-value	p-value	<p>Importance plot Dependent variable: Var24</p>  <p>Рисунок 3.6 – Гистограмма важности входных параметров для моделирования переменной 24</p>	
Var17	7,362727	0,001420		
Var18	6,011034	0,003578		
Var16	5,585845	0,005867		
Var4	3,477018	0,028282		

Таблица 3.14 – Оценки точности построения регрессионной модели для параметра 24

Метод	Критерии оценки точности построения регрессионной модели без оптимизации параметров / с оптимизацией параметров	
	Средняя относительная ошибка моделирования, %	
Искусственные нейронные сети	11,3	5,8
Многомерные регрессионные сплайны	6,2	4,4
Деревья решений	20,3	9,6
Генетическое программирование	11,6	8,6
Непараметрическая регрессия	10,9	6,9

Переменная 25

Результаты отбора входных переменных приведены в таблице 3.15.

Таблица 3.15 – Результаты отбора переменных для моделирования параметра 25

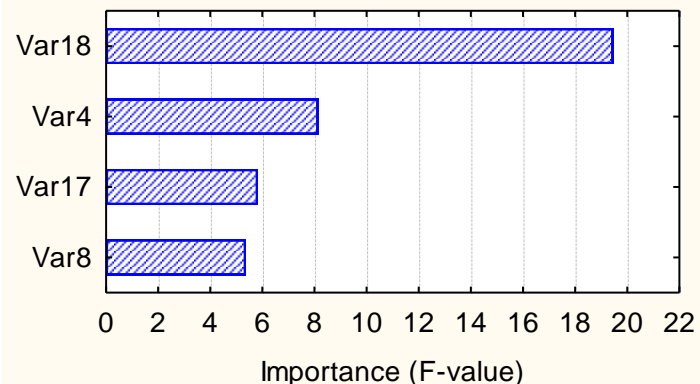
Значения критериев отбора переменных			Графическая интерпретация результата
	F-value	p-value	<p>Importance plot Dependent variable: Var25</p>  <p>Рисунок 3.7 – Гистограмма важности входных параметров для моделирования переменной 25</p>
Var18	19,45778	0,000007	
Var4	8,13474	0,000847	
Var17	5,81986	0,004118	
Var8	5,35658	0,005860	

Таблица 3.16 – Оценки точности построения регрессионной модели для параметра 25

Метод	Критерии оценки точности построения регрессионной модели без оптимизации параметров / с оптимизацией параметров	
	Средняя относительная ошибка моделирования, %	
Искусственные нейронные сети	13,9	5,2
Многомерные регрессионные сплайны	7,9	4,2
Деревья решений	15,6	8,6
Генетическое программирование	17,4	8,1
Непараметрическая регрессия	11,4	6,5

Переменная 26

Результаты отбора входных переменных приведены в таблице 3.17.

Таблица 3.17 – Результаты отбора переменных для моделирования параметра 26

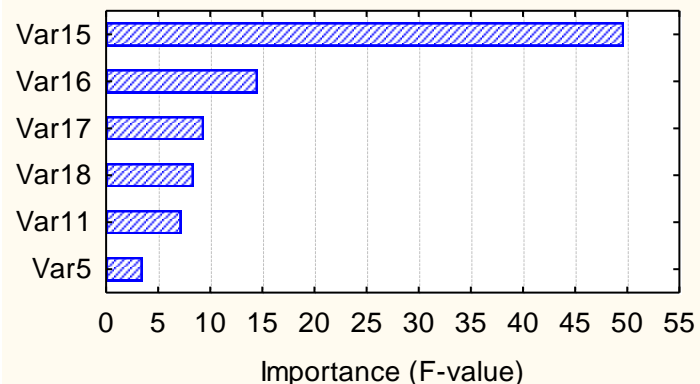
Значения критериев отбора переменных			Графическая интерпретация результата	
	F-value	p-value	<p>Importance plot Dependent variable: Var26</p>  <p>Рисунок 3.8 – Гистограмма важности входных параметров для моделирования переменной 26</p>	
Var15	49,67606	0,000000		
Var16	14,53241	0,000048		
Var17	9,36476	0,000435		
Var18	8,38320	0,000758		
Var11	7,21279	0,005394		
Var5	3,48366	0,028099		

Таблица 3.18 – Оценки точности построения регрессионной модели для параметра 26

Метод	Критерии оценки точности построения регрессионной модели без оптимизации параметров / с оптимизацией параметров	
	Средняя относительная ошибка моделирования, %	
Искусственные нейронные сети	10,9	7,9
Многомерные регрессионные сплайны	9,6	3,2
Деревья решений	18,6	9,6
Генетическое программирование	11,8	6,7
Непараметрическая регрессия	11,5	6,6

Переменная 27

Результаты отбора входных переменных приведены в таблице 3.19.

Таблица 3.19 – Результаты отбора переменных для моделирования параметра 27

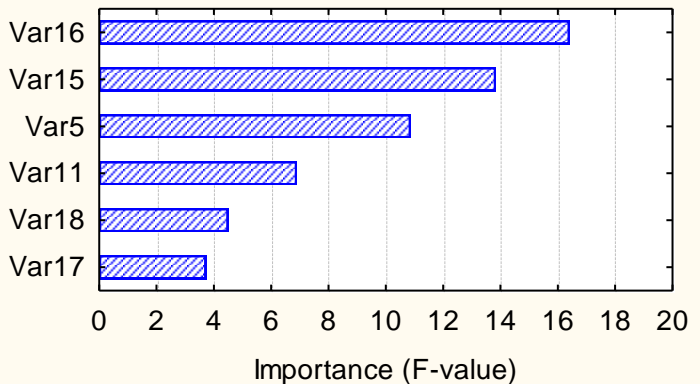
Значения критериев отбора переменных			Графическая интерпретация результата
	F-value	p-value	<p>Importance plot Dependent variable: Var27</p>  <p>Рисунок 3.9 – Гистограмма важности входных параметров для моделирования переменной 27</p>
Var16	16,40897	0,000024	
Var15	13,83841	0,000064	
Var5	10,86701	0,000201	
Var11	6,89391	0,006421	
Var18	4,50240	0,011770	
Var17	3,72945	0,023497	

Таблица 3.20 – Оценки точности построения регрессионной модели для параметра 27

Метод	Критерии оценки точности построения регрессионной модели без оптимизации параметров / с оптимизацией параметров	
	Средняя относительная ошибка моделирования, %	
Искусственные нейронные сети	9,8	6,2
Многомерные регрессионные сплайны	12,6	5,9
Деревья решений	20,1	8,7
Генетическое программирование	15,7	8,7
Непараметрическая регрессия	14,4	6,8

Переменная 28

Результаты отбора входных переменных приведены в таблице 3.21.

Таблица 3.21 – Результаты отбора переменных для моделирования параметра 28

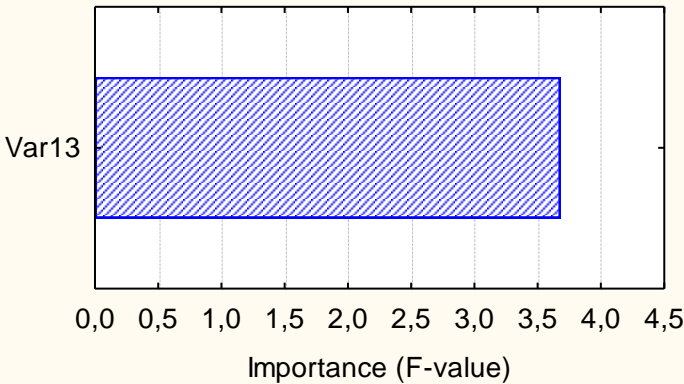
Значения критериев отбора переменных			Графическая интерпретация результата
	F-value	p-value	<p>Importance plot Dependent variable: Var28</p>  <p>Var13</p> <p>0,0 0,5 1,0 1,5 2,0 2,5 3,0 3,5 4,0 4,5</p> <p>Importance (F-value)</p> <p>Рисунок 3.10 – Гистограмма важности входных параметров для моделирования переменной 28</p>
Var13	3,679506	0,047012	

Таблица 3.22 – Оценки точности построения регрессионной модели для параметра 28

Метод	Критерии оценки точности построения регрессионной модели без оптимизации параметров / с оптимизацией параметров	
	Средняя относительная ошибка моделирования, %	
Искусственные нейронные сети	11,4091	5,73233
Многомерные регрессионные сплайны	6,93597	2,25053
Деревья решений	18,059	8,45299
Генетическое программирование	17,0927	8,79182
Непараметрическая регрессия	13,4456	6,13745

Переменная 29

Результаты отбора входных переменных приведены в таблице 3.23.

Таблица 3.23 – Результаты отбора переменных для моделирования параметра 29

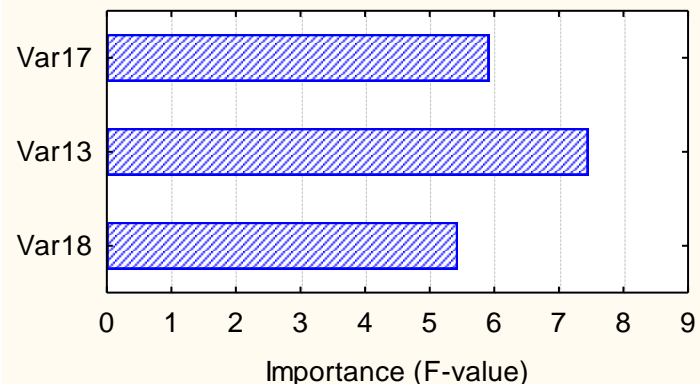
Значения критериев отбора переменных			Графическая интерпретация результата	
	F-value	p-value	<p>Importance plot Dependent variable: Var29</p>  <p>Рисунок 3.11 – Гистограмма важности входных параметров для моделирования переменной 29</p>	
Var17	5,921060	0,003821		
Var13	7,455418	0,004735		
Var18	5,435175	0,005513		

Таблица 3.24 – Оценки точности построения регрессионной модели для параметра 29

Метод	Критерии оценки точности построения регрессионной модели без оптимизации параметров / с оптимизацией параметров	
	Средняя относительная ошибка моделирования, %	
Искусственные нейронные сети	9,3	5,4
Многомерные регрессионные сплайны	6,4	4,9
Деревья решений	18,0	8,3
Генетическое программирование	21,7	8,5
Непараметрическая регрессия	13,8	7,2

Переменная 30

Результаты отбора входных переменных приведены в таблице 3.25.

Таблица 3.25 – Результаты отбора переменных для моделирования параметра 30

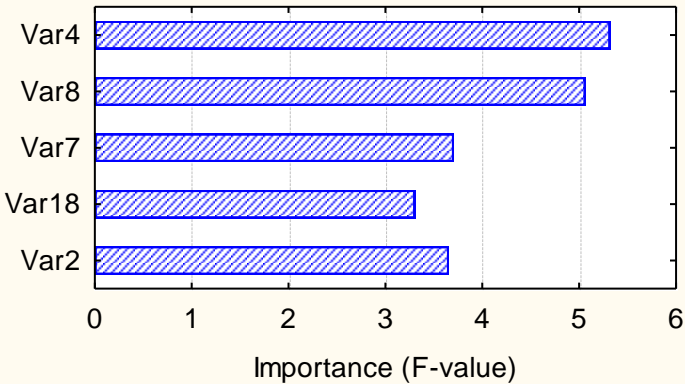
Значения критериев отбора переменных			Графическая интерпретация результата	
	F-value	p-value	<p>Importance plot Dependent variable: Var30</p>  <p>Рисунок 3.12 – Гистограмма важности входных параметров для моделирования переменной 30</p>	
Var4	5,320755	0,005663		
Var8	5,063690	0,007389		
Var7	3,707252	0,023991		
Var18	3,306071	0,035265		
Var2	3,656146	0,047785		

Таблица 3.26 – Оценки точности построения регрессионной модели для параметра 30

Метод	Критерии оценки точности построения регрессионной модели без оптимизации параметров / с оптимизацией параметров	
	Средняя относительная ошибка моделирования, %	
Искусственные нейронные сети	17,5	5,8
Многомерные регрессионные сплайны	8,6	2,9
Деревья решений	19,2	8,7
Генетическое программирование	11,2	7,5
Непараметрическая регрессия	9,9	7,4

3.4 Анализ результатов численных исследований методов моделирования и оптимизации моделей технологических систем

Полученные в ходе численных исследований результаты были обработаны с помощью статистических методов для оценки значимости. Для проверки по всем моделируемым параметрам рассматриваемой технологической установки использовался метод дисперсионного анализа ANOVA.

Данные были получены в ходе построения регрессионных моделей для расчета и прогнозирования параметров аппарата колонного типа. Для оценки эффективности использования моделей различных типов результаты анализировались как отдельно для каждого рассматриваемого параметра, так и в среднем для множества рассматриваемых параметров. Описание и краткий анализ результатов по каждому параметру даны в соответствующих подразделах.

Результаты полученные для множества моделируемых параметров в среднем приведены в таблице 3.27.

Таблица 3.27 – Оценки точности построения регрессионной модели по всем моделируемым параметрам

Метод	Критерии оценки точности построения регрессионной модели без оптимизации параметров / с оптимизацией параметров	
	Средняя относительная ошибка моделирования, %	
Искусственные нейронные сети	11,9	6,1
Многомерные регрессионные сплайны	8,2	3,8
Деревья решений	17,8	8,9
Генетическое программирование	15,6	7,8
Непараметрическая регрессия	13,4	7,6

Таким образом, если рассматривать все моделируемые параметры в целом, то для большинства параметров (а именно, для 9 из моделируемых 11) лучшие результаты были получены с использованием метода многомерных регрессионных сплайнов. Средняя ошибка моделирования для регрессионных моделей, полученных с использованием данного метода без параметрической оптимизации моделей составила 8.2%. В среднем для рассматриваемых регрессионных моделей ошибка моделирования составила 12,6%, что является существенным значением, потенциально ограничивающим возможность их эффективного применения для моделирования технологических установок нефтеперерабатывающих производств и расчёта управляющих воздействий и параметров для них. Это свидетельствует о необходимости и рациональности использования предлагаемых в работе дополнительных процедур для параметрической адаптации получаемых регрессионных моделей, которые могут рассматриваться как начальные решения для получения более эффективных (в смысле критерия точности) регрессионных моделей.

Полученные результаты и анализ их статистической обработки доказывают, что применение дополнительных алгоритмов параметрической оптимизации моделей на основе эволюционного генетического алгоритма позволяет существенно сократить модель. Это достигается за счет глубокой адаптации параметров моделей за счет эффективного поиска набора оптимальных (или близких к ним) параметров моделей в соответствующем пространстве. Несмотря на то, что размерность соответствующей оптимизационной задачи значительна, что делает затруднительным применение классических методов оптимизации и методов прямого полного перебора, используемый в работе эвристический алгоритм оптимизации регрессионных моделей для расчёта параметров технологических установок продемонстрировал высокую эффективность.

Как видно из результатов, приведенных в таблице 3.27 применение дополнительной процедуры параметрической оптимизации позволило существенно сократить ошибку моделирования более чем в два раза: с 15,6% до

7,2%. Для наиболее эффективного метода – метода регрессионных сплайнов – ошибка моделирования после параметрической оптимизации модели составило 2,8%. После параметрической оптимизации точность моделей, по экспертным оценкам соответствующих специалистов, является удовлетворительной, и соответствующие модели могут быть использованы для моделирования и прогнозирования параметров процессов технологических установок, и как следствия для расчёта уровней управляющих параметров таких установок.

Отметим, что параметрическая оптимизация позволила существенно повысить точность для моделей получаемых всеми методами, при этом даже наихудшие модели в смысле критерия точности моделирования, после предлагаемой в работе параметрической оптимизации, оказались более точными по сравнению с лучшим методом многомерных регрессионных сплайнов без параметрической оптимизации. Данный результат может быть использован следующим образом, особенно с учетом того, что ни один из методов не оказался эффективнее остальных на всех задачах, - возможно использовать любой из рассмотренных методов в сочетании с генетическим алгоритмом параметрической оптимизации моделей для построения эффективных регрессионных моделей для расчета уровней управляющих параметров технологических установок.

Выводы

В ходе выполнения диссертационного исследования были проведены численные эксперименты для оценки эффективности методов построения регрессионных моделей технологических установок нефтеперерабатывающих производств (на примере ректификационной колонны). Для построения моделей и оценки их эффективности (в смысле критерия точности моделей) использовались выборки наблюдений технологических параметров.

Для получения статистически значимых результатов использовался подход, основанный на многократной перекрестной проверке, широко ис-

пользуемый при исследований методов построения регрессионных моделей. Полученные статистические оценки критерий точности построения регрессионных моделей были проверены для подтверждения получения статистически значимых и статистически различных результатов с помощью методов ANOVA.

Полученные результаты показывают, что в целом, рассмотренные в диссертации методы позволяют строить регрессионные модели, позволяющие сравнительно быстро рассчитывать оценки выходных параметров ректификационных колонн для оценки влияния входных факторов и расчёта управляющих значений на основе этих параметров. Однако, как показали численные исследования точность моделей, построенных различными методами различается. В среднем, на множестве моделируемых параметров наиболее эффективным оказался метод многомерных адаптивных сплайнов. Данный метод с использованием рассматриваемых в работе выборок наблюдений позволяет строить модели со средней (по набору моделируемых параметров) ошибкой моделирования в 8,2%.

Для повышения точности получаемых моделей в работе было предложено использовать эволюционные алгоритмы оптимизации, которые позволили в рамках постановки задачи оптимизации эффективно настроить коэффициенты получаемых регрессионных моделей. Далее в ходе численных исследований была произведена оценка эффективности оптимизации параметров моделей технологических установок с использованием рассматриваемого в работе набора данных. Полученные результаты свидетельствуют о том, что параметрическая оптимизация моделей позволила сократить ошибку моделирования более чем в два раза, в среднем до 7,2%. Для метода многомерных регрессионных сплайнов, продемонстрировавшего лучшие результаты, как и в случае неприменения параметрической оптимизации, средняя ошибка моделирования составила 2,8%.

Полученные результаты свидетельствуют о возможности замены «традиционных» моделей быстрыми регрессионными моделями. Расчет и прогно-

зирование параметров технологических установок, в том числе для выработки управляющих воздействия, с использованием таких моделей возможен в режиме реального времени и не требует применения специализированных высокопроизводительных ЭВМ, оснащение которыми автоматизированных рабочих мест операторов таких технологических установок видится нецелесообразным.

ЗАКЛЮЧЕНИЕ

В ходе диссертационного исследования решены следующие задачи и получены следующие результаты:

1. Рассмотрено устройство технологической вакуумной колонной установки, используемой на предприятия нефтегазопереработки, описаны основные параметры технологических процессов, выполняемых на данной установке, проведен статистический анализ оценок связей между входными и выходными параметрами соответствующего технологического процесса.

2. Выполнены описание и анализ существующих алгоритмов построения регрессионных моделей, использующих в качестве основы для построения модели: искусственные нейронные сети, символьные регрессионные модели, синтезированные методом генетического программирования, многомерные регрессионные сплайны, регрессионные деревья решений и непараметрические регрессионные модели.

3. Сформулирована задача параметрической оптимизации регрессионных моделей технологических установок и технологических систем нефтеперерабатывающих производств. Оценены параметры задачи, позволяющие утверждать о необходимости использования эффективных оптимизационных алгоритмов, способных выполнять оптимизацию в многомерных пространствах с учетом высокой сложности целевой функции. Задача рассмотрена на пример моделирования параметров вакуумной колонной установки.

4. Рассмотрены методы параметрической оптимизации регрессионных моделей, в результате оценки параметров соответствующей задачи оптимизации предложено использовать эволюционный генетический алгоритм для оптимизации параметров моделей управления технологических систем нефтегазового комплекса на примере рассматриваемой технологической установки нефтепереработки. Выполнено предварительное исследование эффективности выбранного метода оптимизации на наборе тестовых функций,

имитирующих сложные целевые функции задач параметрической оптимизации моделей. По результатам определены параметры реализующего выбранный метод алгоритма, обеспечивающие наилучшую эффективность в среднем на множестве задач.

5. Получены и статистически обработаны результаты численного экспериментального исследования методов построения регрессионных моделей технологических производственных установок нефтегазового комплекса на примере технологической вакуумной установки колонного типа. Результаты доказывают эффективность сформулированного в работе предложения по использованию быстрых регрессионных моделей для оценки, прогнозирования и определения значений параметров, используемых для управления технологическими установками, используемыми в составе производственных систем нефтегазового комплекса.

6. Полученные в ходе численных исследований результаты также подтверждают эффективность сформулированного в работе предложения по использовании эволюционного генетического алгоритма для параметрической оптимизации моделей технологических установок, эксплуатируемых в составе производственных систем нефтегазового комплекса. Это подтверждается получением эффективных моделей, обеспечивающих ошибку моделирования менее 3% для 11 параметров вакуумной колонны, что в соответствии с экспертными оценками является достаточным уровнем для применения данных моделей в качестве основы для моделирования параметров соответствующих технологических процессов и выбора эффективных значений управляющих параметров с учетом модельных оценок.

СПИСОК ИСПОЛЬЗОВАННЫХ ИСТОЧНИКОВ

1. Васильев В.И. и др. Многоуровневое управление динамическими объектами. М.: Наука, 1987. - 309 с.
2. Вережкин А.П. Системные принципы и критерии при разработке автоматизированных технологических комплексов. // Прикладные проблемы управления макросистемами / Тез. докл. 3-й Всесоюзной школы АН СССР, ВНИИСИ. - М.: 1989. - С. 196-198.
3. Современное состояние теории исследования операций. / Под ред. Моисеева Н.Н. - М.: Наука, 1979. - 464 с.
4. Шамкин В.Н. Дестабилизационное управление сложными технологическими объектами. / Автореферат дисс. д.т.н., Тамбов, 1977 - 32 с.
5. Алиев Р. А. и др. Производственные системы с искусственным интеллектом. - М.: Радио и связь, 1990. - 264 с.
6. Асаи К. и др. Прикладные нечеткие системы./ Пер. с япон.; под ред. Тэрано Т., Асаи К., Сугэно М. - М.: Мир, 1993. -368с.
7. Арсланов Ф.А., Вережкин А.П., Иванов В.И., Муниров Ю.М., Гарева Р.Г. Моделирование ректификационных колонн установок АВТ для целей оперативного управления по показателям качества. // Исследования, интенсификация и оптимизация химико-технологических систем переработки нефти. - М.: ЦНИИТЭ нефтехим, 1992. С.94-98.
8. Танатаров М.А. и др. Технологические расчеты установок переработки нефти. М.: Химия. 1987. - 352 с.
9. Танатаров М.А. и др. Технологические расчеты установок переработки нефти. М.: Химия. 1987. - 352 с.
10. Кулаков М.В. Технологические измерения и приборы для химических производств. - М.: Машиностроение, 1983. - 424 с.
11. Чельцов А.В. Измерительные устройства для контроля качества нефтепродуктов - М. .Химия. 1981. -261с.
12. Косер Р.Дж. Расчет пределов отбора фракций современными рас-

пределенными системами управления ректификационными колоннами. // Нефть, газ и нефтехимия за рубежом, 1988, № 4, - С. 131-134.

13. А.с.№ 1265540. БИ № 39 от 23.10.86. Способ определения вязкости жидкости и устройство для его осуществления. / Динкель В.Г., Раутенштейн В.Я., Веревкин А.П., Климов А.В.

14. Федеров А.В., Статюха Г.А. Алгоритм принятия решений при управлении сложным химико-технологическим объектом. // Хим. технология. - К.: 1987. №4.

15. Анисимов И.В. Основы автоматического управления технологическими процессами нефтехимической и нефтеперерабатывающей промышленности.- Л.: Химия. 1967.-408.

16. Арсланов Ф.А., Веревкин А.П., Иванов В.И., Муниров Ю.М., Гареев Р.Г. Моделирование ректификационных колонн установок АВТ для целей оперативного управления по показателям качества. // Исследования, интенсификация и оптимизация химико-технологических систем переработки нефти. - М.: ЦНИИ ТЭнефтехим, 1992. С.94-98.

17. Гибаев И.Ф., Веревкин А.П. Имитатор автоматической системы ситуационного управления. // Материалы 46-й научн. техн. конф. студентов, аспирантов и молодых ученых. - Уфа, 1995.-С.65.

18. Бакан Г.М., Камета А.С., Сальников Н.М. Математическая модель процесса переработки нефти в сложной ректификационной колонне. / Ин-т кибернетики АН УССР. - Киев, 1983. - 27 с.

19. Танатаров М.А. и др. Технологические расчеты установок переработки нефти. М.: Химия. 1987. - 352 с.

20. Серебрянский А.Я. Управление установками каталитического крекинга. - М.: Химия, 1983.

21. Шамкин В.Н. Дестабилизационное управление сложными технологическими объектами. / Автореферат дисс. д.т.н., Тамбов, 1977 - 32 с

22. Балакирев В.С., Володин В.М., Цирлин А.М. Оптимальное управление процессами химической технологии (Экстремальные задачи в

АСУ). - М.: Химия, 1978.-383 с.

23. Танатаров М.А. и др. Технологические расчеты установок переработки нефти. М.: Химия. 1987. - 352 с.

24. Барский, А.Б. Нейронные сети: распознавание, управление, принятие решений / А. Б. Барский — М.: Финансы и статистика, 2004. — 176 с.

25. Галушкин, А.И. Нейрокомпьютеры и их применение.: Учеб. пособие для вузов / Общая редакция А.И. Галушкина. – М.: ИПРЖР, 2000.

26. Осовский, С. Нейронные сети для обработки информации: Пер. с польского И. Д. Рудинского / С. Осовский. – М.: Финансы и статистика, 2002. – 344 с.

27. Ежов, А.А. Нейрокомпьютинг и его применения в экономике и бизнесе/ А.А. Ежов, С.А. Шумский. – М.: 1998.

28. Комашинский, В.И. Нейронные сети и их применение в системах управления и связи / В.И. Комашинский, Д.А. Смирнов. – М.: Горячая линия – Телеком, 2003. – 94 с.

29. Миркес, Е.М. Нейроинформатика: учеб. пособие / Е.М. Миркес. – Красноярск: ИПЦ КГТУ, 2002.

30. Хайкин, Саймон Нейронные сети: полный курс, 2-е издание.: Пер. с англ. / Саймон Хайкин.– М.: Издательский дом "Вильямс", 2006. – 1104с.

31. Круглов, В.В. Искусственные нейронные сети. Теория и практика. – 2-е изд. / В.В. Борисов, В.В. Круглов. – М: Горячая линия-Телеком, 2002. – 382 с.

32. Мак-Каллок, У.С. Логическое исчисление идей, относящихся к нервной активности / У.С. Мак-Каллок, В. Питтс // В сб.: «Автоматы» под ред. К.Э. Шеннона и Дж. Маккарти. – М.: Изд-во иностр. лит., 1956. – С.363–384.

33. Рутковская, Д. Нейронные сети, генетические алгоритмы и нечеткие системы: Пер. с польского И. Д. Рудинского / М. Пилинский, Д. Рутковская, Л. Рутковский. – М.: Горячая линия-Телеком, 2006. – 452 с.

34. Комашинский, В.И. Нейронные сети и их применение в системах управления и связи / В.И. Комашинский, Д.А. Смирнов. – М.: Горячая линия –Телеком, 2003. – 94 с.
35. Розенблатт, Ф. Принципы нейродинамики: Перцептроны и теория механизмов мозга / Ф. Розенблатт — М.: Мир, 1965. — 480 с.
36. Fahlman, S.E. "The cascade-correlation learning architecture" // S.E. Fahlman, C. Lebiere // *Advances in Neural Information Processing Systems*, 1990, vol. 2, pp. 524-532.
37. Lee, S.-W. "Off-line recognition of totally unconstrained handwritten numerals using multilayer cluster neural network" / S.-W. Lee // *IEEE Trans. Pattern Anal. Machine Intell.*, vol. 18, June 1996. pp. 648–652.
38. Эшби, У.Р. Конструкция мозга. Происхождение адаптивного поведения/ У.Р. Эшби. – М.: ИЛ, 1962. — 397 с.
39. Fels, S.S. "Glove-talk: A neural network interface between a data-glove and a speech synthesizer" / S.S. Fels, G.E. Hinton // *IEEE Trans. Neural Networks*, vol. 4, Jan. 1993. pp. 2–8.
40. Knerr, S. "Handwritten digit recognition by neural networks with single-layer training" / G. Dreyfus, S. Knerr, L. Personnaz // *IEEE Trans. Neural Networks*, vol. 3, Nov. 1992. – pp. 962–968.
41. Weigend, A.S. "Generalization by weight-elimination with application to forecasting" / B.A. Huberman, D.E. Rumelhart, A.S. Weigend // *Advances in Neural Information Processing Systems*, 1991, vol. 3, pp. 875-882.
42. Комарцова, Л.Г. Нейрокомпьютеры: Учеб. пособие для вузов./ Л.Г. Комарцова, А.В. Максимов. – 2-е изд. – М.: Изд-во МГТУ имени Н.Э. Баумана, 2004. – 400 с.
43. Friedman, J.H. Multivariate adaptive regression splines, *The Annals of Statistics*, 19, 1 (1991) 1- 141.
44. Elith, J., and Leathwick, J. Predicting species distribution from museum and herbarium records using multiresponse models fitted with multivariate adaptive regression splines, *Diversity and Distributions*, 13, 3 (2007) 265-275.

45. Deconinck, E., Coomons, D., and Heyden, Y.V. Explorations of linear modeling techniques and their combinations with multivariate adaptive regression splines to predict gastro-intestinal absorption of drugs, *Journal of Pharmaceutical and Biomedical Analysis*, 43, 1 (2007) 119-130.
46. Haas, H., and Kubin, G. A multi-band nonlinear oscillator model for speech, *Conference Record of the Thirty- Second Asilomar Conference on Signals, Systems and Computers*, 1 (1998) 338-342.
47. Crino, S., and Brown, D.E. Global optimization with multivariate adaptive regression splines, *IEEE Transactions on Systems Man and Cybernetics Part b — cybernetics*, 37, 2 (2007) 333-340.
48. Yerlikaya, F. A new contribution to nonlinear robust regression and classification with MARS and its applications to data mining for quality control in manufacturing, M.Sc., Department of Scientific Computing (2008) 1-102.
49. Di, W. Long Term Fixed Mortgage Rate Prediction Using Multivariate Adaptive Regression Splines, School of Computer Engineering, Nanyang Technological University, 2006.
50. Koza, John R. Genetic programming tutorial. URL: <http://www.genetic-programming.com/gpanimatedtutorial.html>.
51. Koza, John R. The Genetic Programming Paradigm: Genetically Breeding Populations of Computer Programs to Solve Problems / John R. Koza. - Cambridge, MA: MIT Press, 1992.
52. Медведев А.В. Анализ данных в задаче идентификации. В кн. Компьютерный анализ данных моделирования. Т.2.- Минск: БГУ, 1995,с.201-206.
53. Медведев А. В. Непараметрические системы адаптации / А.В. Медведев. – Новосибирск: Наука, 1983. – 174 с.
54. Blagodyir I. V. Nonparametric algorithms in information technologies of modeling and control for a power unit [Text] / I. V. Blagodyir, I. A. Krasnochtanova, A. V. Medvedev, A. B. Panshin ; Сиб. гос. технол. ун-т
55. Эйкхофф Ц. Основы идентификации систем управления. Оцени-

вание параметров и состояния: Пер. с англ. / Под ред. Н.С. Райбмана. – М.: Мир, 1975 – 261 с.

56. Holland, J.H. Adaptation in natural and artificial systems / J.H. Holland – Ann Arbor. MI: University of Michigan Press, 1975.

57. Сопов, Е.А. Разработка и исследование вероятностных эволюционных алгоритмов для моделирования и оптимизации сложных систем: дисс. магистра / Е.А. Сопов – Красноярск: СибГАУ 2004 – 117 с.

58. Goldberg, D.E. Genetic algorithms in search, optimization and machine learning [Text] / D.E. Goldberg. - Reading, MA: Addison-Wesley, 1989.

59. Павловский М.М., Козлов И.А., Сывороткин Е.Г. Приближенная зависимость параметров качества фракций от выходов этих фракций при первичной переработке нефти. // Химия и технология топлив и масел, 1972, №8.

60. Расчеты основных процессов и аппаратов нефтепереработки: Справочник. - М.: 1979.

ПРИЛОЖЕНИЕ А

В частности, приборы для анализа фракционного состава и ряд других приборов качества имеют следующие метрологические, динамические и надежность характеристики:

- сходимост показаний: $1.3...6^{\circ}\text{C}$;
- воспроизводимость (по сравнению с ГОСТ 2177 - 66): $2...8^{\circ}\text{C}$;
- основная погрешность: $4...8^{\circ}\text{C}$;
- время измерения (цикл измерения): 35...60 мин;
- запаздывание: до 15 мин;
- вероятность безотказной работы $P(1000 \text{ ч}) = 0,9$; интенсивность отказов $\Lambda, \ll 10^{-4}, \text{ч}^{-1}$;
- время восстановления - 4 часа;
- интенсивность восстановления $\psi \ll 0,25, \text{ч}^{-1}$.

Приборы для анализа температуры вспышки:

- отклонение от лабораторных определений $\pm (2...3)^{\circ}\text{C}$;
- сходимост - $3...6^{\circ}\text{C}$;
- воспроизводимость - $4...8^{\circ}\text{C}$.

Для вискозиметров:

- основная погрешность - $1,5...2,5\%$;
- дополнительная погрешность - до $1,2\%$;
- время запаздывания - до 8 мин.;
- вероятность безотказной работы $P(2000 \text{ ч}) = 0,8$; $\Lambda * 10^{-4}, \text{ч}^{-1}$.

ПРИЛОЖЕНИЕ Б

Результаты корреляционного анализа технологических параметров колонны установки К-5. Красным цветом выделены корреляции, значимые при уровне доверительной вероятности 0,95.

	Var19	Var20	Var21	Var22	Var23	Var24	Var25	Var26	Var27	Var28	Var29	Var30
Var1	0,09	-0,23	-0,02	-0,16	0,10	-0,00	0,17	-0,33	-0,27	-0,12	0,14	0,26
Var2	0,31	0,08	-0,08	0,03	0,14	0,17	0,33	0,05	0,10	0,00	0,18	0,55
Var3	0,20	0,22	-0,16	0,10	-0,03	0,09	-0,08	0,40	0,33	0,08	-0,07	0,00
Var4	0,22	0,04	-0,06	0,17	0,33	0,32	0,55	-0,06	0,05	0,11	0,40	0,65
Var5	0,35	0,33	-0,08	0,16	-0,01	0,17	0,05	0,47	0,40	0,09	-0,03	0,18
Var6	0,76	0,60	0,48	0,43	0,30	0,46	0,47	0,47	0,56	0,10	0,35	0,59
Var7	0,44	0,22	0,41	0,32	0,38	0,47	0,60	0,08	0,25	0,10	0,46	0,62
Var8	0,15	-0,04	0,28	0,21	0,43	0,45	0,65	-0,19	0,02	0,10	0,50	0,65
Var9	0,38	0,33	0,18	0,23	0,08	0,20	-0,06	0,45	0,40	0,11	0,04	-0,12
Var10	0,21	0,20	-0,13	0,11	0,02	0,09	-0,01	0,32	0,36	0,10	-0,01	0,06
Var11	0,73	0,81	0,58	0,43	0,09	0,24	0,14	0,67	0,66	0,11	0,10	0,19
Var12	-0,20	-0,19	0,26	0,24	0,31	0,40	0,48	-0,16	0,05	0,11	0,40	0,27
Var13	-0,30	-0,28	0,07	0,32	0,61	0,44	0,50	-0,22	-0,12	0,47	0,58	0,30
Var14	0,22	0,21	0,05	0,00	-0,05	-0,00	0,18	0,10	0,11	-0,02	0,01	0,21
Var15	0,79	0,88	0,56	0,46	0,10	0,27	0,14	0,76	0,77	0,13	0,10	0,20
Var16	0,59	0,69	0,82	0,71	0,42	0,67	0,62	0,60	0,81	0,24	0,51	0,48
Var17	0,17	0,25	0,60	0,71	0,73	0,77	0,79	0,23	0,45	0,51	0,78	0,54
Var18	0,36	0,42	0,64	0,71	0,69	0,77	0,93	0,31	0,54	0,50	0,78	0,72

Исчисленные результаты расчета описательных статистик для технологических параметров колонны установки К-5.

	Mean	Minimum	Maximum
Var1	87,50	76,00	96,00
Var2	385,75	380,00	390,00
Var3	98,90	87,00	109,00
Var4	356,40	353,00	364,00
Var5	168,85	162,00	176,00
Var6	240,55	236,00	244,00
Var7	285,00	282,00	288,00
Var8	312,65	310,00	316,00
Var9	0,90	0,70	1,10
Var10	0,21	0,10	0,30
Var11	2,00	1,50	2,50
Var12	2,50	2,00	3,00
Var13	4,03	3,50	4,50
Var14	12,00	11,50	12,50
Var15	2,21	1,70	2,70
Var16	4,71	4,20	5,20
Var17	8,73	8,20	9,20
Var18	20,73	20,20	21,20
Var19	351,37	345,90	357,20
Var20	313,48	307,40	318,70
Var21	392,75	389,00	397,00
Var22	354,80	351,10	360,20
Var23	430,61	420,90	433,30
Var24	380,68	378,00	382,60
Var25	481,09	478,00	483,80
Var26	271,56	265,80	274,80
Var27	313,81	311,50	317,00
Var28	341,92	340,10	351,90
Var29	471,21	462,40	475,10
Var30	535,03	531,80	537,60

Примеры графоаналитических результатов статистического анализа технологических параметров.

1. Переменная 19:

